

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

ZAVRŠNI RAD

Maja Trstenjak

Zagreb, 2015.

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

ZAVRŠNI RAD

Mentori:

Prof. dr. sc. Predrag Ćosić, dipl. inž.

Student:

Maja Trstenjak

Zagreb, 2015.

Izjavljujem da sam ovaj rad izradio samostalno koristeći stečena znanja tijekom studija i navedenu literaturu.

Zahvaljujem se mentoru, prof. Predragu Ćosiću, g. Silviju Merle iz Metal Producta i g. Stipi Mariću iz Strojotehnike.

Maja Trstenjak



SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

Središnje povjerenstvo za završne i diplomske ispite
 Povjerenstvo za završne ispite studija strojarstva za smjerove:
 proizvodno inženjerstvo, računalno inženjerstvo, industrijsko inženjerstvo i menadžment, inženjerstvo
 materijala i mehatronika i robotika



Sveučilište u Zagrebu	
Fakultet strojarstva i brodogradnje	
Datum 24-02-2015.	Prilog
Klasa: 602-04/15-6/3	
Ur.broj: 15-1703-15-36	

ZAVRŠNI ZADATAK

Student:

MAJA TRSTENJAK

Mat. br.: 0035185947

Naslov rada na
hrvatskom jeziku:Podrška odlučivanja pri odabiru alatnih strojeva u investicijskom
projektuNaslov rada na
engleskom jeziku:Decision Support in Selection Machine Tools during Investment
Project

Opis zadatka:

U projektu nabave opreme, odabir alatnih strojeva ima tehnološke, organizacijske i ekonomske kriterije. Stoga, u završnom radu treba opisati značaj odabira opreme (alatnih strojeva), te definiranje kriterija odabira (značajke strojeva, rok isporuke, količina izradaka, složenost izradaka, zauzetost strojeva i slično). Opisati sustav za potporu i odlučivanje AHP metodu (analitičko hijerarhijski proces) u softverskoj aplikaciji "Expert Choice" te ga primijeniti za odabir alatnih strojeva za reprezentativni asortiman proizvoda realne tvrtke.

Zadatak zadan:

25. studenog 2014.

Rok predaje rada:

1. rok: 26. veljače 2015.

2. rok: 17. rujna 2015.

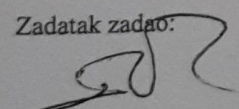
Predviđeni datumi obrane:

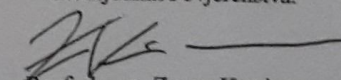
1. rok: 2., 3., i 4. ožujka 2015.

2. rok: 21., 22., i 23. rujna 2015.

Predsjednik Povjerenstva:

Zadatak zadan:


 Prof. dr. sc. Predrag Čosić


 Prof. dr. sc. Zoran Kunica

SADRŽAJ

SADRŽAJ	II
POPIS SLIKA	IV
POPIS TABLICA	V
POPIS KRATICA	VI
POPIS OZNAKA	VII
SAŽETAK	VIII
SUMMARY	IX
1. UVOD	1
2. DSS I VRSTE DSS-a	2
2.1. Povijest DSS-a	2
2.2. Vrste DSS-a	4
2.2.1. DSS zasnovan na modelu	4
2.2.2. DSS zasnovan na dokumentima	5
2.2.3. DSS zasnovan na znanju	5
2.2.4. DSS zasnovan na podacima	6
2.2.5. DSS zasnovan na komunikacijama	6
2.2.6. DSS zasnovan na webu	7
3. AHP METODA	8
3.1. Postupak	8
3.1.1. Strukturiranje problema	8
3.1.2. Saatyjeva skala	9
3.1.3. Određivanje najznačajnijeg kriterija i alternativa	11
3.2. Prednosti i nedostaci AHP metode	11
3.2.1. Prednosti	11
3.2.2. Nedostaci	12
4. EXPERT CHOICE	13
4.1. Struktura i sučelje programa	13
4.1.1. Prikaz rezultata	16
5. ODABIR ALATNOG STROJA	17
5.1. Kratak opis i povijest poduzeća	17
5.1.1. Razlog odabira	18
5.2. Vrste proizvoda i njihove karakteristike	18
5.3. Kriteriji za odabir novog alatnog stroja	21
5.3.1. Ponderiranje kriterija	23
5.4. Odabir najbolje alternative	24
5.4.1.1. Ponderiranje alternativa	27
5.5. Rezultati AHP metode u Expert Choiceu	28
5.5.1. Konzistentnost	29
5.5.2. Rezultati s obzirom na najvažnije kriterije	29
5.5.3. Graf osjetljivosti	33

5.6. Konačni odabir	35
5.7. Odabir rabljenih strojeva.....	36
5.7.1. Prednosti i nedostaci rabljenih strojeva.....	39
5.8. Gradnja vlastitih strojeva	40
5.8.1. Prednosti i nedostaci gradnje vlastitih strojeva.	41
6. ISPLATIVOST ODABRANOG STROJA.....	42
7. PRIMJENJIVOST METODE U REALNOJ PROIZVODNJI.....	44
8. ZAKLJUČAK.....	45
LITERATURA.....	46
PRILOZI	47

POPIS SLIKA

Slika 3.1.	Strukturiranje problema AHP metode [2]	9
Slika 3.2.	Saatyjeva skala relativne važnosti [5]	9
Slika 3.3.	Saatyjeva skala – značenje pojedinih vrijednosti [2]	10
Slika 4.1.	Osnovno sučelje Expert Choicea [5]	13
Slika 4.2.	Numerički kriteriji [5]	14
Slika 4.3.	Opisno uspoređivanje kriterija [5]	15
Slika 4.4.	Grafičko uspoređivanje kriterija [5]	15
Slika 4.5.	Grafovi osjetljivosti [5]	16
Slika 5.1.	Stezaljka odvodnika prednapona	19
Slika 5.2.	Stopnica A1 (BLM 28/95-13-KZ)	19
Slika 5.3.	Tijelo MP1030-donje	19
Slika 5.4.	Kučiste V-kleme	19
Slika 5.5.	Tijelo za stezaljke	19
Slika 5.6.	Hijerarhijski prikaz odabranih kriterija	22
Slika 5.7.	HAAS EC-400 [8]	25
Slika 5.8.	HAAS VF1 [8]	25
Slika 5.9.	HURCO VMX10i [9]	25
Slika 5.10.	HURCO VMX 24i [9]	26
Slika 5.11.	HURCO HMX500i [9]	26
Slika 5.12.	Rezultati cilja	28
Slika 5.13.	Konzistentnost alternativa	29
Slika 5.14.	Alternative s obzirom na tehnološke kriterije	30
Slika 5.15.	Alternative s obzirom na tehnološke parametre	30
Slika 5.16.	Alternative s obzirom na pomoćno vrijeme	30
Slika 5.17.	Alternative s obzirom na proizvodne troškove	31
Slika 5.18.	Alternative s obzirom na financijske kriterije	32
Slika 5.19.	Graf osjetljivosti cilja – primarni	33
Slika 5.20.	Graf osjetljivosti s obzirom s najvećim udjelom financijskih kriterija	34
Slika 5.21.	Rezultati cilja za manju seriju	34
Slika 5.22.	HAAS VF-2 rabljeni, slika iz oglasa [11]	37
Slika 5.23.	HAAS VF-2 rabljeni – slika iz oglasa [12]	37
Slika 5.24.	HAAS VF-3 rabljeni – slika iz oglasa [13]	38
Slika 5.25.	Hurco VM1 rabljeni [14]	38

POPIS TABLICA

Tablica 1. Karakteristike proizvoda.....	20
Tablica 2. Usporedba specifikacija alatnih strojeva [8], [9]	26
Tablica 3. Proračun B/T za veliku serije.....	35
Tablica 4. Proračun B/T za malu seriju	36
Tablica 5. Podaci o proizvodnji [15]	42

POPIS KRATICA

DSS – *Decision Support System* – podrška pri donošenju odluke

MIS – *Management Information Systems* – menadžerski informacijski sustavi

MDS – *Management Decision System* – menadžerski sustav za donošenje odluke

IFPS – *Interactive Financial Planning System* – interaktivni finansijski sustav planiranja

OLAP – *Online Analytical Processing*

AHP – *Analytic Hierarchy Process* – analitički hijerarhijski proces

POPIS OZNAKA

Oznaka	Jedinica	Opis
n	-	broj kriterija
λ_{\max}	-	konstanta
CI	-	indeks konzistentnosti
CR	-	omjer konzistentnosti
RI	-	indeks konzistentnosti
B	-	benefiti
T	Euro	troškovi

SAŽETAK

U ovom radu opisan je postupak odabira novog alatnog stroja primjenom analitičkog hijerarhijskog procesa (AHP metode) na temelju kojeg radi korišteni program *Expert Choice*. Opisan je postupak i matematički model analitičkog hijerarhijskog procesa te su navedeni njegovi prednosti i nedostaci.

Odabiru alatnog stroja pristupa se kao ozbiljnom investicijskom poduhvatu za poduzeće te se razmatraju i mogućnosti kupnje rabljenih strojeva te gradnje vlastitih strojeva.

Ključne riječi: Podrška pri donošenju odluke, Analitički hijerarhijski proces, Odabir alatnih strojeva

SUMMARY

This paper describes machine tool selection process using the Analytic Hierarchy Process (AHP method) implemented in Expert Choice software. The procedure and mathematical model of AHP method is also described with its advantages and disadvantages.

Machine tool selection is understood as serious investment for companies. Purchase of used machinery or building of own is also considered, described with its advantages and disadvantages.

Key words: Decision Support Systems, Analytic Hierarchy Process, Machine Tools Selection

1. UVOD

Odabir alatnih strojeva zahtjevan je financijski poduhvat za svako poduzeće, bilo da se radi o malim strojarskim radionicama ili velikim proizvodnim sustavima. Stoga je potrebno odluku donijeti pravilno i objektivno kako ne bi došlo do neželjenih gubitaka. Postoje mnogi načini za donošenje odluka, a kao jedan od mogućih načina je uz pomoć sustava za potporu donošenju odluka. Korištenje matematičkih modela kojima se evaluiraju odabrani kriteriji i potencijalni izbori je poželjno. Jedan od takvih je i AHP metoda koja je temelj rada mnogih programa, od kojih je najpoznatiji *Expert Choice*.

Koje je sve kriterije potrebno uzeti u obzir kako bi se proces odlučivanja proveo što temeljitije te tako rezultirao najboljim odabirom, odnosno, donošenjem najbolje odluke; pitanje je koje je temeljno za ovakve situacije u kojima se nalaze većina poduzeća čiji proizvodni program zahtjeva korištenje alatnih strojeva.

Treba biti svjestan da, uobičajeno, procjena nabavke opreme eksperata, bazirano na iskustvu, znanju te osnovnim kriterijima: veza proizvodnog asortimana, složenosti proizvoda, količine s produktivnosti stroja rezultira usporedbom više neponderiranih kriterija. Budući da je to klasičan višekriterijalan problem, a klasični modeli optimiranja ne dolaze u obzir, pribjegava se drugim modelima odlučivanja. To se, kolokvijalno, smatra intuicijom eksperata.

Kod odabira i nabave alatnih strojeva, s druge strane, nameće se pitanje treba li kupiti potpuno nove, rabljene ili napraviti vlastite strojeve, prilagođene vlastitom proizvodnom procesu.

U nepredvidljivoj okolini u kojoj poduzeća posluju i zahtjevima tržišta koja zahtijevaju što veću fleksibilnost i više je nego potrebno razmotriti i pravilno riješiti navedene izazove kako bi poduzeće poslovalo s dobitkom.

2. DSS I VRSTE DSS-a

DSS (eng. *Decision Support System*) naziv je za računalne programe koji se koriste kao pomoć pri odlučivanju na bilo kojoj razini upravljanja; s naglaskom na odlučivanju kod slaboustruktuiranih i nestruktuiranih zadataka. DSS je računalni sustav za organizaciju informacija, identifikaciju i dohvat informacija, analizu i transformaciju informacija, izbor modela odlučivanja i analizu dobivenih rezultata. Usmjeren je rješavanju dobro struktuiranih i slaboustruktuiranih problema, na sadašnje i buduće odluke, na kontrolu i planiranje. Mora omogućavati fleksibilnost i odlučivanju i implementaciji odluka. Odluke u kojima će se koristiti mogu biti jednostavne i vrlo složene. [1]

2.1. Povijest DSS-a

Sustavi za potporu odlučivanju prisutni su već dugi niz godina. Razvoj DSS-a počeo je krajem šezdesetih godina prošlog stoljeća, a sama se implementacija dogodila sredinom osamdesetih godina. Proces prvotnih implementacija završava sredinom devedesetih, implementacijom DSS-a zasnovanog na *webu*.

Sustavi su se mogli razvijati usporedno s razvojem računalnih sustava i opreme. Prve ideje datiraju iz 1965. godine od kada postoje prvi zapisi o idejama, ljudima, sustavima i tehnologijama vezanim za ove sustave.

Razvoj DSS-a vodio je k razvoju samog načina poslovanja i organizacije proizvodnje. Sustavi su se razvijali kako bi omogućili i olakšali samostalno donošenje što objektivnijih odluka, dinamičniji rad u timovima te bolju organizaciju hijerarhije poduzeća zbog sustava koji pomaže kod donošenju vrlo važnih i što je moguće racionalnijih odluka.

Bez adekvatne postojeće tehnologije, bilo je teško i skupo izgraditi velike informacijske sustave. U to je vrijeme IBM razvio sustav „360“ i omogućio praktičniji i jeftiniji razvoj menadžerskih informacijskih sustava (eng. *Management Information Systems – MIS*) u velikim kompanijama. Sustav je omogućio menadžmentu strukturirane i periodične izvještaje. Također, bile su dostupne mnoge informacije iz računovodskih i financijskih sustava.

U kasnim šezdesetima počeo je razvoj DSS sustava zasnovanog na modelu jer je u tom periodu to bilo puno praktičnije. Bio je poznat kao *Menadžerski sustav odlučivanja*.

Dva pionira DSS-a, Peter Keen i Charles Stabell, tvrde da se koncept sustava za donošenje odluka razvio iz teoretskih razmatranja na *Cairnegie* institutu za tehnologiju i tehničkog rada na interaktivnim kompjutorskim sustavima, ponajviše provedenih na MIT-u šezdesetih godina.

Sedamdesetih su se pojavili prvi članci na temu DSS-a, strateškog planiranja sistema i potpore donošenju odluka. 1966. i 1967. Scott Morton istraživao je kako bi kompjuterski i analitički modeli mogli pomoći menadžerima pri donošenju ključnih odluka. Odradio je eksperiment u kojem su menadžeri koristili MDS (eng. *Management Decision System*). Marketinški i proizvodni menadžeri koristili su MDS kako bi koordinirali planirane proizvodnje opreme za pranje rublja. Istraživanje je provedeno na tadašnjoj dostupnoj opremi te je to prvo istraživanje koje je implementiralo, definiralo i testiralo DSS zasnovan na modelu.

Sedamdesetih godina provedeno je istraživanje korištenja DSS-a kod donošenja svakodnevnih investicijskih odluka kako bi menadžment podebljao svoj portfelj.

1974. godine Gordon Davis, profesor sa Sveučilišta u Minnesoti, objavio je važan članak o MIS-u. Definirao je MIS kao „integrirani, čovjek/stroj sustav koji osigurava informacije za potporu operacijama, menadžmentu i odlukama pri donošenju odluka u svim funkcijama u organizaciji“. Taj je članak bila prekretnica za utjelovljenje istraživanje DSS-a i primjenu u praksi.

Sljedećih se godina o DSS-u raspravljalo na raznim konferencijama, od kojih je prva održana 1981. u Atlanti, na kojoj su stručnjaci s MIT-a, Keen i Scott Morton, postavili temelje analize, dizajna, implementacije, evaluacije i razvoja DSS-a.

Knjiga Ralpa Spraguea i Erica Carlsona iz 1982. Godine, *Building Effective Decision Support Systems*, bila je vrlo važna jer je objasnila DSS baze podataka i DSS zasnovan na modelu. Knjiga je dala jednostavan i razumljiv uvid u to kako bi organizacije trebale koristiti i izgraditi DSS.

Do kraja sedamdesetih DSS je mogao biti potpora operacijama, financijskom menadžmentu i strateškom donošenju odluka. DSS je mogao koristiti podatke iz sistema kao *Geodata Analysis* i *Display System*, strukturirane multidimenzionalne podatke i nestrukturirane dokumente. Mnogi su modeli koristili optimizaciju i simulaciju. Također, statistički su paketi prepoznati kao temelj za izgradnju DSS-a.

Kod financijskog planiranja sustava, ovi su alati postali jako popularni. Ideja je bila kreirati univerzalni jezik koji bi stručnim osobama omogućio gradnju modela bez napora. Popularni sistem za planiranje IFPS (eng. *Interactive Financial Planning System*) koristio se do sredine devedesetih godina. Po uzoru na njegov način rada, sredinom osamdesetih razvijen je DSS zasnovan na modelu.

Početkom osamdesetih, znanstvenici su razvili novu kategoriju DSS-a. Bio je to DSS zasnovan na podacima. Krajem osamdesetih predstavljen je koncept i metode kojima se donošenje odluka omogućuje korištenjem potpornih sustava baziranih na činjenicama. Ponekad su to knjige, izvještaji ili informacijski sustavi.

Devedesetih se godina pojavio DSS koji je koristio *Oracle* ili *DB2*. DSS zasnovan na modelu bio je u domeni operacijskih istraživanja i nije bio dio informacijskih sustava.

Tada je došlo do promjene i prelaska na DSS zasnovan na komunikacijama. 1994. mnoge su tvrtke počele s nadogradnjom mrežne infrastrukture, a sve je to zbog razvoja Interneta. DSS zasnovan na *webu* počeo se razvijati 1995. godine. S razvojem Interneta, razvoj DSS-a je također počeo rasti i njegova se primjena počela puno brže širiti. [1]

2.2. Vrste DSS-a

Postoji nekoliko vrsta DSS-a. Razlikuju se s obzirom na stupanj razvoja, vrijeme u kojem su nastale i jednostavnost primjene.

DSS se dijeli na:

- DSS zasnovan na modelu
- DSS zasnovan na dokumentima
- DSS zasnovan na znanju
- DSS zasnovan na podacima
- DSS zasnovan na komunikacijama
- DSS zasnovan na webu [1]

2.2.1. DSS zasnovan na modelu

DSS zasnovan na modelu naglašava pristup i manipulaciju modelom, na primjer statističkim, financijskim, optimizacijskim ili simulacijskim. Jednostavni statistički i analitički alati osiguravaju elementarni nivo funkcionalnosti. Neki OLAP (eng. *Online Analytical Processing*) sustavi koji dopuštaju kompleksnu analizu podataka mogu se klasificirati kao

hibridni DSS sustavi koji osiguravaju modeliranje, vađenje podataka i sumiranje funkcionalnosti podataka. DSS koriste kompleksne financijske, simulacijske, optimizacijske i višekriterijalne modele kako bi omogućili potporu kod donošenja odluka. Koriste podatke i parametre koje su osigurali donositelji odluke kako bi pomogli budućim sudionicima u tim situacijama pri analizi situacije.

2.2.2. DSS zasnovan na dokumentima

DSS zasnovan na dokumentima usmjeren je preuzimanju i upravljanju nestrukturiranih dokumenata. Dokumenti se mogu pojaviti u mnogim oblicima, no tri su najčešće kategorije: **oralni, pisani i vizualni**. Primjeri oralnih dokumenata su transkribirane konverzacije, vizualni su dokumenti, reportaže s vijestima ili televizijske reklame dok u pisane dokumente spadaju pisani izvještaji, katalozi, pisma potrošača ili e-mailovi.

To je računalom podržan sustav koji integrira mnoge kapacitete i tehnologije obrade kako bi se podaci lako izvadili i analizirali pri donošenju odluke. *Web* omogućava pristup velikim bazama podataka koje se sastoje od dokumenata u obliku hiperteksta, slika, zvukova i video zapisa. Tražilice su snažna i izrazito korisna pomoć u DSS-u zasnovanom na dokumentima.

2.2.3. DSS zasnovan na znanju

DSS zasnovan na znanju može predložiti ili preporučiti pothvate menadžerima u donošenju odluka pri rješavanju problema. Ekspertiza se sastoji od znanja o određenoj domeni, razumijevanja problema unutar te domene i sposobnost rješavanja nekih od problema. Slični je koncept „rudarenja podataka“ (eng. *Data mining*). Odnosi se na klasu analitičkih aplikacija koje traže skrivene uzorke u bazi podataka. Rudarenje podacima je proces pretraživanja velike baze podataka kako bi se ostvarile poveznice između podataka. Alati koji se koriste za DSS zasnovan na znanju ponekad se nazivaju *Inteligentna potpora odlučivanju* (eng. *Intelligent Decision Support Methods*). Alati za rudarenje podacima mogu se koristiti kako bi se stvorio hibridni DSS koji sadrži glavne komponente podataka i znanja.

Ovi sustavi koriste znanje pohranjeno u obliku pravila, okvira i informacija. Ljudi stupaju u interakciju s programom kada žele riješiti neki problem. Sustav se bazira na preporukama baziranih na ljudskom znanju i pomažu rješavanju limitiranog broja slučajeva.

DSS zasnovan na znanju razlikuje se od DSS-a zasnovanog na modelu u načinu na koji je znanje prezentirano i kako se obrađuje. Razlika postoji jer većina ekspertnih sustava pokušava simulirati razumne ljudske procese.

Može dati prijedloge ili preporuke bazirane na određenim kriterijima. Takvi sustavi zahtijevaju interakciju između čovjeka i računala. Napredni analitički alati kao što je rudarenje podacima mogu se integrirati s ovim DSS-om kako bi se lakše pronašli skriveni uzorci. Postoji mogućnost samoučenja, identifikacije povezanosti između podataka i ako je potrebno, izvođenja heurističkih operacija. Ove mogućnosti pretvaraju ga u inteligentni sustav, povećan je kapacitet rješavanja problema i povećana je sigurnost prijedloga. Važno je spomenuti kako predstavljanje znanja ovdje igra glavnu ulogu. Dobro definirano znanje uključuje sustave bazirane na pravilima, semantičkim *web* i okvirnim sustavima. Sustav baziran na pravilima sadrži pravila u bazi podataka.

2.2.4. DSS zasnovan na podacima

Većina DSS-a zasnovanog na podacima predviđeni su za menadžere, osoblje i dobavljače proizvoda ili usluga. Koristi se za ispitivanje baze podataka ili skladišta podataka u traženju određenih odgovora za određene svrhe. Angažiran je preko glavnog „okvirnog sustava“ (eng. *main frame system*), poveznice klijent/server ili preko *weba*.

DSS zasnovan na podacima je najčešći DSS. Osigurava operacijsku i stratešku poslovnu inteligenciju koja koristi interne, a ponekad i eksterne, podatke kompanije. Ključ uspješnog DSS-a zasnovanog na podacima je u lakom i brzom pristupu velikom broju pouzdanih, dobro organiziranih i višedimenzijskih podataka. Omogućuje *ad hoc* filtriranje i vađenje podataka. Sustav korisnicima omogućuje sistematsko pretraživanje i vađenje podataka pohranjenih u računalu, što se često provodi korištenjem padajućeg menija, upitnici su obično predefinirani i korisnici imaju *drill-down* mogućnosti. Korisnici mogu često promijeniti razine agregacije, od općeg do detaljnog (eng. *drill-down*). Korisnicima je omogućeno korištenje različitih vrsta prikaza podataka kao što su *scatter* dijagrami, *bar* i *pie* dijagrami koje interaktivno mogu mijenjati. Također, omogućen je proračun deskriptivnom statistikom kako bi se sumirali opisani podaci, kreirale linije trenda kretanja podataka i međusobno povezali podaci.

2.2.5. DSS zasnovan na komunikacijama

DSS zasnovan na komunikacijama uključuje računalne, kolaboracijske i komunikacijske tehnologije za podršku grupi u njenim zadacima. On može, ali i ne mora uključivati i donošenje odluka. Zapravo svaki DSS koji uključuje podršku grupnom radu spada u ovu kategoriju.

2.2.6. DSS zasnovan na webu

U skladu s trendovima i potrebama korisnika, istraživanja DSS-a su se tijekom vremena usmjerila u četiri smjera:

- prema inteligentnim računalnim sustavima,
- prema aplikacijama modela,
- prema modelu rješavanja problema i
- prema korisničkom sučelju.

Primarni DSS sadržavao je *ad hoc* upite, alate za izvještavanje, optimizacijske i simulacijske modele, OLAP, pretraživanje podataka i njihovu vizualizaciju. Danas su DSS aplikacije proširene na kolaborativni DSS, pregovarački DSS, DSS baziran na znanju i DSS baziran na *webu*.

Web se danas sve više koristi kao klijent/server platforma u mnogim poslovnim organizacijama zbog niskih troškova softvera, instalacije i održavanja. Samim time i rješenja bazirana na *webu* imaju olakšan pristup, analizu i distribuciju informacija iz baze podataka organizacije, putem OLAP-a. OLAP je tehnologija koja omogućava manipulaciju podacima organizacije kroz više dimenzija kao što su proizvod, vrijeme, mjesto itd. Internet i intranet su tijekom prethodnih godina pružili široku mogućnosti izgradnje DSS-a koji se može nositi s problemima globalne prirode. HTML 2.0 u obliku tagova i tabela je prekretnica u razvoju DSS-a baziranih na *webu*

DSS baziran na *webu* je sustav koji komunicira informacijama ili alatima za podršku odlučivanju kroz *web* okruženje (internet, ekstranet i intranet) koristeći *web* tehnologije. Na ovaj način donošenje odluka je efikasnije, jer se smanjuju troškovi implementacije modela, a i sama razmjena informacija je bolja. Power D.J. definirao je DSS baziran na webu kao „*kompjuterizirani sustav koji pruža informacije za podršku odlučivanju ili alate za podršku odlučivanju menadžerima ili poslovnim analitičarima pomoću web pretraživača kao što su Netscape Navigator ili Internet Explorer*“. Računalni server, koji je *host* DSS aplikaciji, povezan je na računalo korisnika pomoću mreže s TCP/IP protokolom.

Prednost DSS-a baziranog na *webu* nad klasičnim DSS-om je korištenje *weba* koje olakšava unos podataka i postupak analize, poboljšava način donošenja odluka i smanjuje troškove razvoja. Ključna prednost je također olakšan pristup sustavu i isplativije dobivanje relevantnih informacija.

3. AHP METODA

Vrlo je čest slučaj da je u radu jednog poduzeća potrebno donositi različite odluke od značajne važnosti za poslovanje, a ponekad čak i opstanak samog poduzeća. Donijeti ispravnu odluku je vrlo teško, pogotovo ako se radi o nekoj od neophodnih, važnih ili velikih investicijskih odluka. Ako se donese kriva odluka, mogući su veliki gubici, kako financijski, tako i proizvodni.

Ispravno donošenje odluke o alatnom stroju vrlo je značajno za manja poduzeća koja svoj posao na njima temelje. Također, odabir alatnih strojeva ozbiljan je pothvat i za veća poduzeća koja možda naručuju veću količinu, no značajnost njihove odluke je vrlo utjecajna. U takvim procesima odlučivanja potrebno je donijeti odluku između mnogo različitih kriterija te među njima odabrati najvažniji, a na kraju odabrati najbolji stroj (alternativu).

Jedna od najkorištenijih i najpopularnijih metoda za donošenja odluka u takvim okruženjima je AHP metoda (*Analitički Hijerarhijski Proces*) koja omogućuje odabir najznačajnijeg kriterija i alternative. [2]

3.1. Postupak

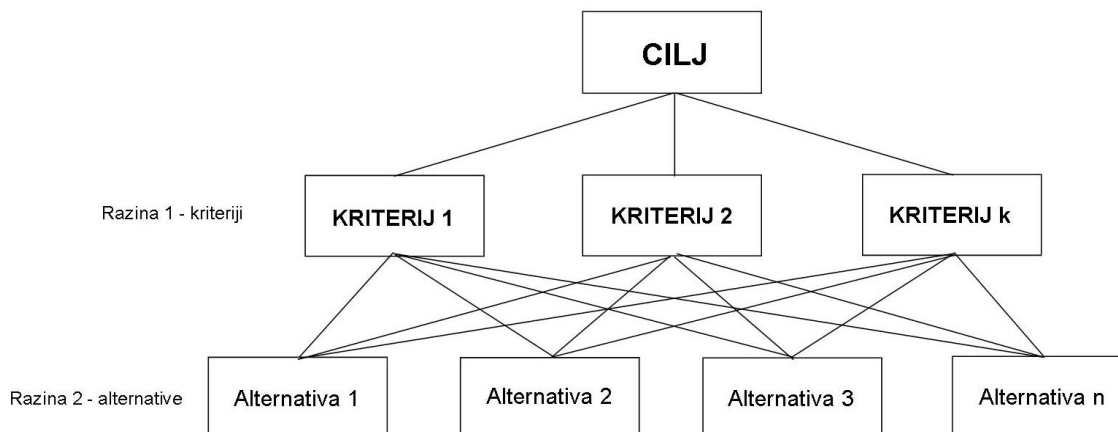
AHP metoda sastoji se od sljedećih faza [3]:

1. Strukturiranje problema
2. Određivanje najznačajnijeg kriterija
3. Određivanje najznačajnije alternative
4. Određivanje konačnog rješenja (cilja)

3.1.1. Strukturiranje problema

AHP metoda strukturira problem na sljedeće razine (Slika 3.1.):

1. razinu cilja
2. razinu kriterija
3. razinu potkriterija
4. razinu alternativa.




Slika 3.1. Strukturiranje problema AHP metode [2]

Na Sliku 3.1. prikazana je struktura problema u AHP metodi na vrhu koje je cilj do kojeg se metodom želi doći. Na sljedećoj razini su kriteriji i potkriteriji dok se na zadnjoj razini nalaze alternative. Sve su razine međusobno povezane.

3.1.2. Saatyjeva skala

Na početku je vrlo važno odabrati cilj (u ovom će Radu to biti „Alatni stroj“). Jednom kada je cilj odabran, potrebno je postaviti odgovarajuće kriterije. Kriterija može biti mnogo te se mora obuhvatiti što širi spektar vrsta kriterija kako bi odluka bila bolja. Nakon toga se kriteriji u parovima uspoređuju i ocjenjuju. Znači, potrebno je provesti ukupno $n * \frac{n-1}{2}$ usporedbi pomoću Saatyjeve skale. [4]

Saatyjeva skala (Slika 3.2.) je prilagođena ljudskoj prirodi odlučivanja i prosuđivanja važnosti.



Slika 3.2. Saatyjeva skala relativne važnosti [5]

Na Sliku 3.2. prikazano je da se Saatyjeva skala sastoji od brojčane skale od jedan do devet, za svaki kriterij/alternativu (u ovom slučaju alternative dva modela automobila) pri čemu jedan označava malu važnost dok devet označava ekstremno veliku važnost, uz dodane međuvrijednosti (Slika 3.3).

Intenzitet važnosti	Definicija	Objašnjenje
1	Jednako važno	Dvije aktivnosti jednako doprinose cilju.
3	Umjereno važnije	Na temelju iskustva i procjena, daje se umjerena prednost jednoj aktivnosti u odnosu na drugu.
5	Strogo važnije	Na temelju iskustva i procjena, strogo se favorizira jedna aktivnost u odnosu na drugu.
7	Vrlo stroga, dokazana važnost	Jedna aktivnost izrazito se favorizira u odnosu na drugu, njezina dominacija dokazuje se u praksi.
9	Ekstremna važnost	Dokazi na temelju kojih se favorizira jedna aktivnost u odnosu na drugu, potvrđeni su s najvećom uvjerljivošću.
2,4,6,8	Međuvrijednosti	
1.1 – 1.9	Decimalne vrijednosti	Pri usporedbi aktivnosti koje su po važnosti blizu jedna drugoj, potrebne su decimalne vrijednosti kako bi se preciznije izrazila razlika u njihovoj važnosti.

Slika 3.3. Saatyjeva skala – značenje pojedinih vrijednosti [2]

Iz Slika 3.3. vidljiva je raspodjela i opis važnosti koje se dodjeljuju kriterijima, odnosno alternativama.

AHP metoda zasniva se na četiri aksioma [4]:

1. Aksiom recipročnosti. Ako je element A n puta značajniji od elementa B, tada je element B $1/n$ puta značajniji od elementa A.
2. Aksiom homogenosti. Usporedba ima smisla jedino ako su elementi usporedivi - npr. ne može se uspoređivati težina komarca i težina slona.
3. Aksiom zavisnosti. Dozvoljava se usporedba među grupom elemenata jednog nivoa u odnosu na element višeg nivoa, tj. usporedbe na nižem nivou zavise od elementa višeg nivoa.
4. Aksiom očekivanja. Svaka promjena u strukturi hijerarhije zahtjeva ponovno računanje prioriteta u novoj hijerarhiji.

3.1.3. Određivanje najznačajnijeg kriterija i alternativa

Kriteriji mogu biti kvalitativni i kvantitativni. Važnost kvalitativnih kriterija se prosuđuje samostalno i prilično subjektivno, jer nije moguće točno prosuditi o važnosti jednog kvalitativnog kriterija naspram drugom. Moguće je znati okvirno (što je u nekim slučajevima dosta pouzdano) koliko je jedan kriterij važniji od drugog i sukladno tome procijeniti njegovu važnost, no kod kvantitativnih kriterija ona je točno poznata. Ista je situacija i s alternativama. Primjer kvalitativnih kriterija su fleksibilnost, pouzdanost, dizajn dok su kvantitativni kriteriji cijena, potrošnja, itd.

Detaljan postupak, primjer i matematički model AHP metode opisan je u Prilogu I.

3.2. Prednosti i nedostaci AHP metode

AHP metoda iskazala se kao jedna od metoda odlučivanja s najboljim uporabnim karakteristikama. Njom je razrađen cijeli proces donošenja odluke, od početka (definiranja cilja, kriterija i alternativa) do kraja (same odluke).

3.2.1. Prednosti

AHP metoda ima niz prednosti kod odlučivanja. [3], [4]

- Metoda je izuzetno prilagođena korisniku kojem je omogućeno njeno jednostavno korištenje. Osim procjenjivanja važnosti različitih kriterija, moguća je usporedba različitih alternativa te provedba simulacija koja prikazuje promjene u izlaznim podacima izmjenom ulaznih podataka.
- Metoda je dokazana u praksi i primjenjuje se već dugi niz godina.
- Omogućena provjera konzistentnosti korisnika.
- AHP metoda omogućava usporedbu kvalitativnih i kvantitativnih kriterija pomoću apsolutne skale za mjerenje i na kraju procjenjivanje te uspoređivanje njihovih važnosti.
- Sami se kriteriji i alternative uspoređuju u parovima, što smanjuje mogućnost pogreške.
- Olakšan i ubrzan proces donošenja odluke, zbog čega se korisnik osjeća puno bolje.
- Stvoreni su uvjeti za timski rad. Tim je u mogućnosti dogovoriti se oko prioriteta i ocjena raznih kriterija te svatko može unijeti svoju varijantu i obrazložiti svoje rezultate.

- Postoje programi koji su vrlo razvijeni i jednostavni za korištenje te omogućuju brzo i jednostavno donošenje odluke (kao npr. *Expert Choice*).
- Ušteda vremena i smanjenje troškova.

3.2.2. Nedostaci

Prednosti AHP metode u nekim slučajevima postaju i nedostaci. [3], [4]

- Čovjek je taj koji donosi odluku o važnosti jednog kriterija ili alternative nasuprot drugoj. Teško je da točno i precizno „odvagnuti“ njenu prevlast ili podčinjenost. Na bodovnoj je skali od jedan do devet teško odabrati točan broj, odnosno, je li kriterij (alternativa) A pet ili četiri puta važnija od kriterija (alternative) B. Jedno od ponuđenih rješenja dao je Hajkowicz (2000.) koji je u svojoj studiji koristio dvobodovnu ljestvicu što je olakšalo i skratilo cjelokupan proces donošenja odluke, što znači da su korisnici morali prosuditi samo je li kriterij (alternativa) više, manje ili jednako važan kao i drugi kriterij (alternativa).
- Kod kompleksnih zadataka postoji veliki broj kriterija i potkriterija pa struktura problema postaje sve kompleksnija, a broj parnih usporedba jako velik što produljuje proces donošenja odluke i otežava cjelokupan proces.

4. EXPERT CHOICE

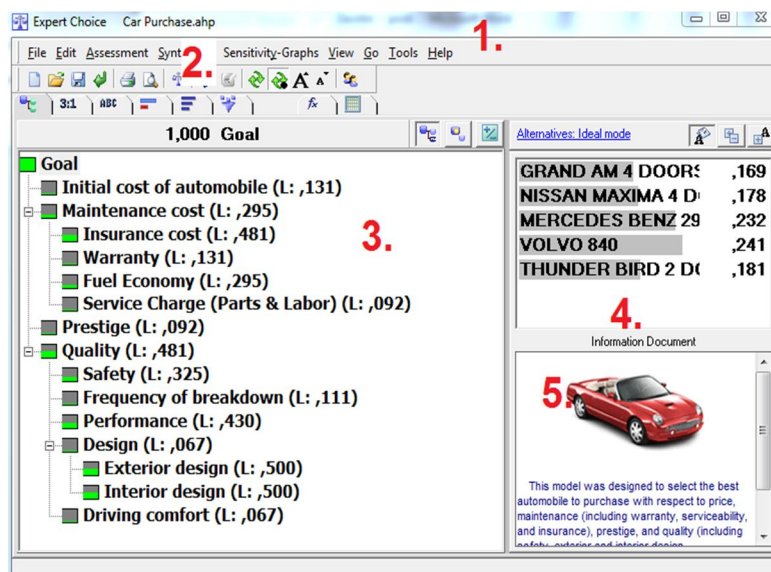
Expert Choice jedan je od najpoznatijih programa za donošenje odluke na temelju više kriterija. U njega je implementiran AHP proces te na taj način sam program funkcionira i prikazuje rezultate. Koristi se u svim granama industrije, kada je potrebno donijeti odluku na temelju više različitih, kvalitativnih i kvantitativnih kriterija pa je tako svoju primjenu pronašao u proizvodnji, upravljanju okolišem i ekologijom te poljoprivredi.

Izradili su ga Thomas Saaty i Ernest Forman 1983. godine. [6]

Program omogućuje formiranje problema i njegovo strukturiranje bez ograničenja na kompleksnost strukture. Omogućeno je zadavanje i uspoređivanje važnosti različitih objekata i alternativa na nekoliko načina. Vrlo je lako sistematiziranje informacija, provedba ekspertiza ili prosudba. Provođenje *what-if* i analize osjetljivosti, odnosno ispitivanje promjene ulazne vrijednosti (eng. *input*) na izlaznu vrijednost (eng. *output*) također je mogućnost programa. U ovom je Završnom radu istraživanje provedeno u *Expert Choiceu 11.5*.

4.1. Struktura i sučelje programa

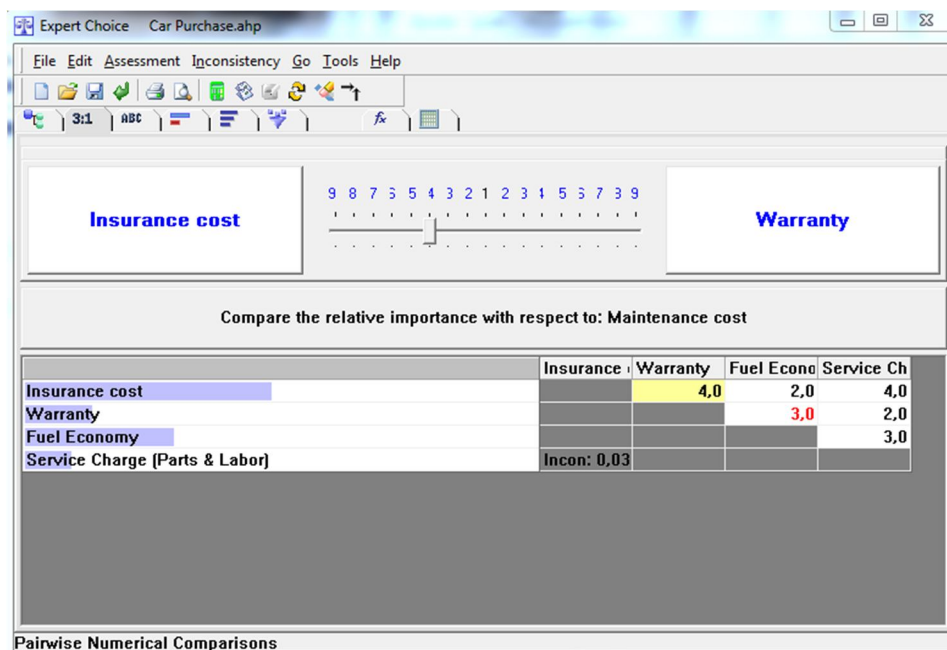
Kao primjer strukture, sučelja, mogućnosti i načina korištenja programa uzet je primjer odlučivanja o optimalnom automobilu, program razrađen kao dio podrške korisnicima programa *Expert Choice* (Slika 4.1.).



Slika 4.1. Osnovno sučelje Expert Choicea [5]

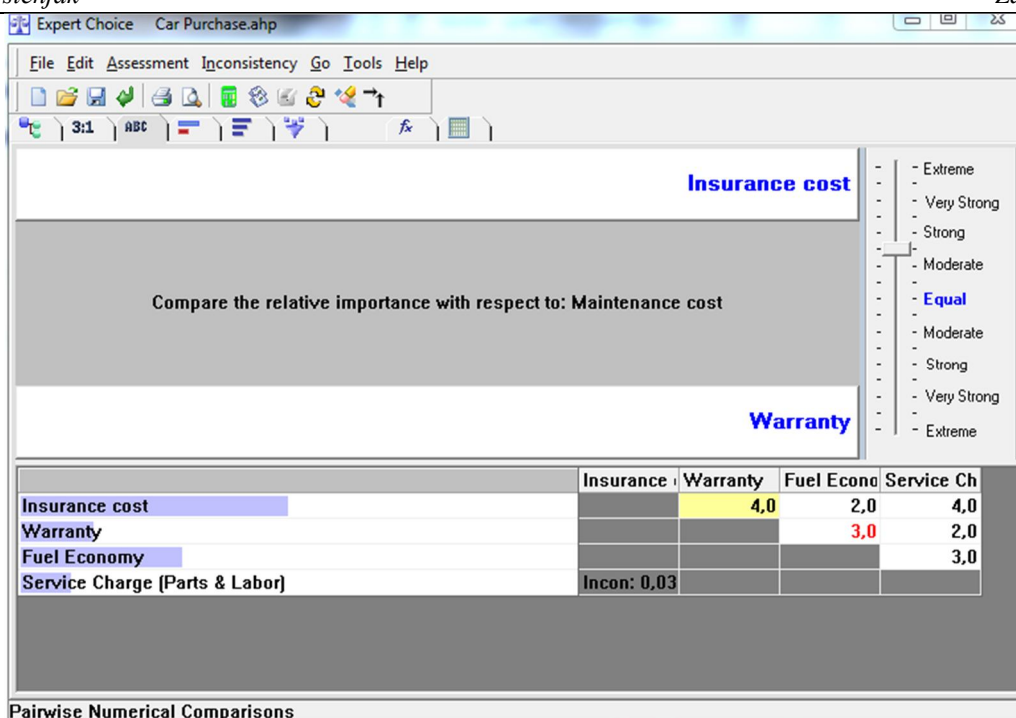
Osnovno sučelje *Expert Choicea* prikazano je na Slika 4.1. Sastoji se od naslovne trake (1.), trake izbornika (2.), stabla s kriterijima (3.), popisa alternativa (4.) te opisa alternativa (5.).

Program nudi uspoređivanje kriterija i alternativa na više različitih načina, koji se biraju u izborniku opcija, u cilju olakšanje upotrebe. Prva je opcija **numeričko uspoređivanje** kriterija/alternativa prikazano na Slika 4.2. Korisnik dodjeljuje važnost određenom kriteriju/alternativi u obliku broja, na skali od jedan do devet. Jedan označava jednaku važnost.



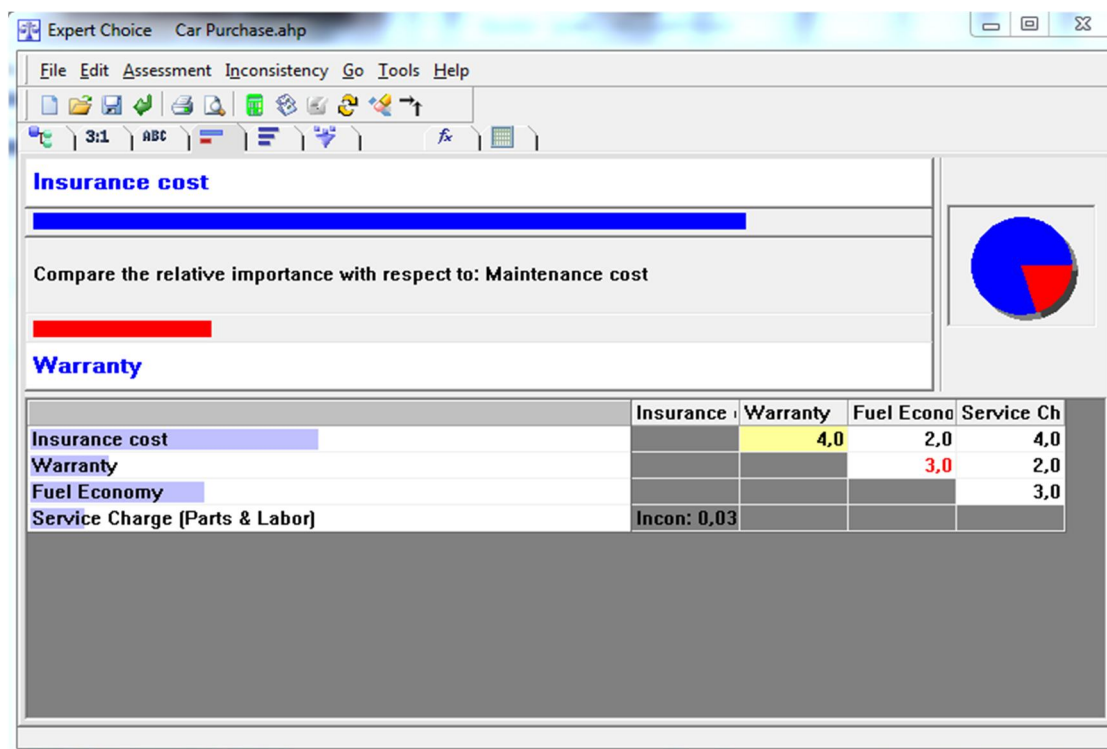
Slika 4.2. Numerički kriteriji [5]

Druga je opcija **opisno uspoređivanje kriterija/alternativa** gdje korisnik opisno dodaje važnost određenom kriteriju/alternativi (Slika 4.3.) Uspoređivanje se vrši pomoću **skale raspona** od jednakog prioriteta (eng. *Equal*) preko umjerenog/jakog prioriteta (eng. *Moderate/Strong*) do najvećeg prioriteta (eng. *Extreme*) uz međustupnjeve.



Slika 4.3. Opisno uspoređivanje kriterija [5]

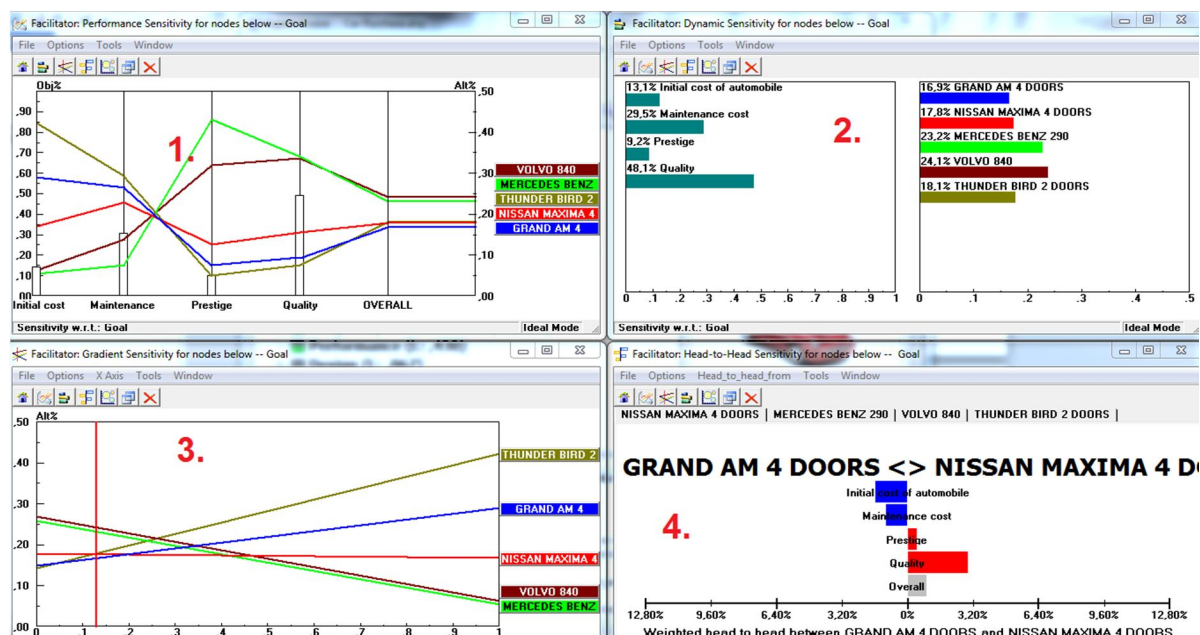
Treća je opcija grafičko uspoređivanje važnosti pomoću grafikona udjela (Slika 4.4.).



Slika 4.4. Grafičko uspoređivanje kriterija [5]

4.1.1. Prikaz rezultata

Rezultati se u *Expert Choiceu* se mogu prikazati na nekoliko načina, *grafovima osjetljivosti*, te se na tim prikazima lako može provesti analiza osjetljivosti (Slika 4.5.).



Slika 4.5. Grafovi osjetljivosti [5]

Postoje četiri vrste grafova osjetljivosti, prikazanih na Slika 4.5.:

- *Performance* (1)
- *Dynamic* (2)
- *Gradient* (3)
- *Head to head* (4)
- *2D* (5)

5. ODABIR ALATNOG STROJA

Kao tvrtka u sklopu čijeg će se djelovanja provesti istraživanje ovog Završnog rada odabrana je *Metal Product* d.o.o. iz Hrašće-Odra, tvornica za proizvodnju elektroopreme.

5.1. Kratak opis i povijest poduzeća

Metal Product d.o.o. osnovana je 1967. kao obrtnička radionica. Od samog su se početka usredotočili na proizvodnju elektroopreme te se kontinuirano razvijaju i šire. Dvije godine nakon, proizvode za potrebe Elektroprivrede Bosne i Hercegovine, a narudžbe su se svakodnevno povećavale kao i broj zaposlenih. 1971. zapošljavali su samo dvanaest radnika (zbog zakona SFRJ koji su ograničavali broj zaposlenih u obrtu, a privatnici nisu mogli zasnovati poduzeća.).

1979. isporučuju nosače izolatora za afričko tržište te kupuju gradište u zagrebačkom prigradskom naselju Odra, gdje su do danas izgrađena tri proizvoda pogona ukupne površine oko 3600 m².

1986. počinju se baviti lijevanjem aluminijskih proizvoda, zbog čega 1989. otkupljuju Ljevaonicu Šikić i preuzimaju kompletan pogon s dvanaest zaposlenih.

1990. u proizvodni program uvrštavaju kabelski spojni i ovjesni pribor za niski, srednji i visoki napon. 1994. započinju kooperaciju s *Tyco Electronics Raychem* GmbH iz Njemačke na konfekcioniranju i distribuciji toplo sakupljačkog kabelskog pribora u programu elektroopreme, a širenje nastavljaju sa sklapanjem ugovora s finskom tvrtkom ABB o proizvodnji rastavljača za srednji napon te Siemensom za isporuku opreme na tržište BIH.

1996. osnivaju proizvodni pogon u Sarajevu, a 2001. potpisuju Protokol o osnivanju zajedničke tvornice *Wam Product* u Brezničkom Humu s *Wam Grupa Italy*, gdje grade i nove proizvodne pogone.

Danas imaju devedesetak zaposlenih te njihov proizvodni program obuhvaća proizvodnju elektro opreme, kabelskog i spojnog pribora za niski, srednji i visoki napon, opremu za izolirane i neizolirane nadzemne mreže, lijevanje obojenih metala tlačnim lijevom, kokilnim lijevom i lijevom u pijesak te obradom odvajanjem čestica.

Jedna od karakteristika ovog poduzeća je stalno ulaganje u djelatnike, informacijsku opremu i CNC tehnologiju kako bi poboljšali kvalitetu vlastitih proizvoda i omogućili bolje poslovanje.

[7]

5.1.1. Razlog odabira

Poduzeće je odabrano upravo zbog činjenice da su se susreli i stalno se susreću s problemom nabave alatnih strojeva te su dosad nabavljali nove, rabljene i sami projektirali, konstruirali i izrađivali svoje alatne strojeve. U ovom će se Završnom radu razmatrati odabir novog alatnog stroja uz kratko objašnjenje mogućnosti odabira rabljenog ili gradnje vlastitog stroja. Nabava novih će se preispitati pomoću naprednih sustava za potporu odlučivanju, korištenjem AHP metoda i pripadajućeg softvera (*Expert Choice*). Nabava rabljenih i izrada vlastitih preispitat će se na temelju iskustva u Metal Productu i usporediti s rezultatima dobivenim AHP metodom. Jedna od najvažnijih problema koji se javlja pri nabavi stroja jest donošenje odluke o tome je li bolje i isplativije kupiti rabljeni ili novi stroj te kako će se koji odraziti na proizvod i poslovanje.

Za potrebe istraživanja odabrano je pet proizvoda iz njihovog stalnog proizvodnog asortimana i na temelju udjela određenih tehnoloških postupaka i potrebne količine proizvoda donijet će se odluka o alternativama, odnosno o prikladnom rangi novog alatnog stroja kojeg je potrebno nabaviti.

O tehnološkim postupcima govorit će se samo u obliku njihovih udjela u proizvodnji samog proizvoda zbog tajnosti dobivenih podataka. Također, točne proizvodne količine nisu poznate jer poduzeće radi na principu dobivenih narudžbi i kao takvo nema određenu proizvodnu politiku ili strategiju pa će se zato uzeti okvirne (procijenjene) godišnje vrijednosti dobivene od strane zaposlenika.

Također, u ovom se istraživanju radi o odabiru alatnih strojeva na koje dolaze poluproizvodi pa će se tako u tehnološkom procesu izrade svakog proizvoda uzeti u obzir samo operacije izvedene na CNC alatnim strojevima, koje je potrebno odabrati (nabaviti).

5.2. Vrste proizvoda i njihove karakteristike

Kao reprezentanti, odabrano je pet proizvoda za čiju je proizvodnju potrebno odabrati alatni stroj. Radi se o proizvodima namijenjenima za primjenu u električnoj industriji. Materijal svih proizvoda su aluminijske legure što znači da za njihovu obradu nije potrebna velika snaga rezanja, odnosno, snaga samog stroja. Proizvodi su odabrani jer u globalu predstavljaju uobičajene operacije obrade koje se obavljaju u ovom poduzeću na CNC strojevima.


Odabrani proizvodi su prikazani na Slikama 5.1, 5.2., 5.3, 5.4, i 5.5.




Slika 5.1. Stezaljka odvodnika prednapona



Slika 5.2. Stopnica Al (BLM 28/95-13-KZ)



Slika 5.3. Tijelo MP1030-donje



Slika 5.4. Kučište V-kleme



Slika 5.5. Tijelo za stezaljke

Njihove karakteristike (dobivene informacije) i usporedba njihovih značajki prikazana je u Tablici 1.

	Stezaljka odvodnika prenapona	Stopica Al (BLM-28/95- 13-KZ)	Tijelo MP1030 - donje	Kučiste V- klem (HEL- 4835-NK)	Tijelo za stezaljke (HEL 48036K
MATERIJAL	AlMgSiO	Al-legura	AlMgSi	AlMgSi	Al-legura
SIROVAC	alumijska šipka $\phi 12$ iz koje se dobiva 73 komada	-	profil 5027, AlMgSi 0,5 F22 (911 komada)	profil Al P202047	-
GABARITI PRIPREMKA	$\phi 12 \times 99,5$	-	-	-	-
GABARITI POLU- PROIZVODA	$70 \times \phi 12 \times 41,5$	$75 \times \phi 24 \times 24$	$40 \times 32,3 \times 27$	$34 \times 48 \times 22$	$27,5 \times 48 \times 18$
GABARITI GOTOVOG PROIZVODA	$70 \times \phi 12 \times 41,5$	$75 \times \phi 24 \times 24$	$40 \times 32,3 \times 27$	$34 \times 48 \times 22$	$27,5 \times 48 \times 18$
KOMADA U SERIJI	9550	9795	11770	54479	6795
POTREBNE OPERACIJE	tokarenje, bušenje, narezivanje navoja, skidanje srha	predbušenje, bušenje, narezivanje navoja	bušenje, narezivanje navoja, glodanje	bušenje, narezivanje navoja, glodanje	bušenje, narezivanje navoja, glodanje

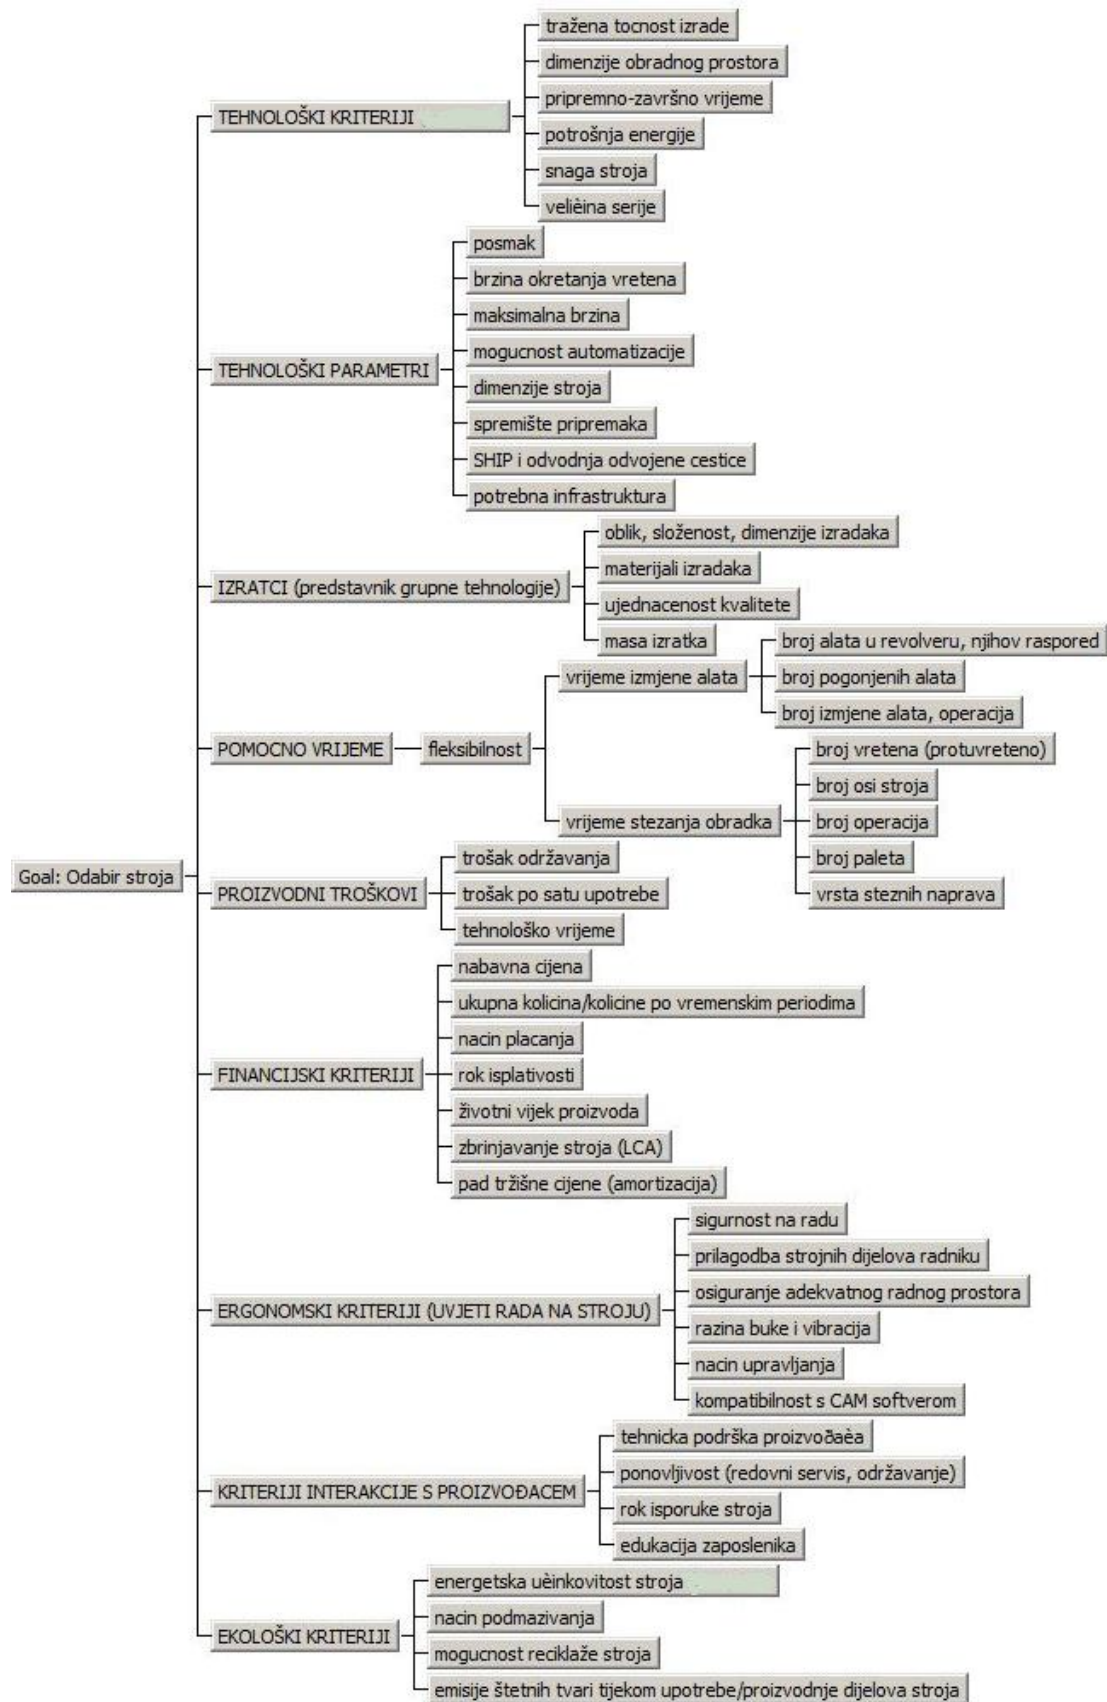
Tablica 1. Karakteristike proizvoda

Iz Tablice 1. vidljivo je da određene dimenzije i podaci o proizvodima nedostaju. Točan tehnološki proces je poslovna tajna, pa će se o vrsti alatnog stroja odlučiti na temelju udjela potrebnih proizvodnih postupaka.

Svaki proizvod zahtjeva operaciju bušenja i narezivanja navoja. Također je potrebno obaviti operacije glodanja, tokarenja i skidanja srha. Iz tih se podataka zaključuje kako je za alatni stroj potrebno odabrati obradni centar koji će omogućiti brzu izmjenu alata te sadržati revolver u koji stanu svi (ili većina) alati potrebnih za navedene operacije.

5.3. Kriteriji za odabir novog alatnog stroja

Vrlo je teško odabrati točne kriterije za odabir alatnih strojeva. Točno rješenje kojem se teži nije poznato, niti kombinacija maksimuma i minimuma. Poznato je samo željeno rješenje za koje se pretpostavlja da će se najviše približiti konačnom, pravom rješenju. Prilično kontradiktorno, konačno, pravo rješenje je nepoznato. Može biti samo plod promišljanja eksperata, tzv. "*brainstorming*". Kriteriji su prikazani na Slici 5.6. Kako bi odluka bila bolja, osim tehnoloških, obuhvaćeni su i ekonomski, ekološki, ergonomske te kriteriji odnosa s dobavljačem.



Slika 5.6. Hijerarhijski prikaz odabranih kriterija

5.3.1. Ponderiranje kriterija

Kriteriji su ponderirani prema podacima iz literature te iskustava eksperata.

Kriteriji kojima je dana najveća važnost u odnosu na ostale su:

- dimenzije obradnog prostora
- veličina serije
- broj alata
- vrsta steznih naprava
- snaga stroja
- način upravljanja
- kompatibilnost s CAM softverom
- broj osi
- cijena

Obradni prostor je u korelaciji s veličinom samih proizvoda. Budući da su odabrani proizvodi u prosjeku gabarita do 100 mm (točnije 72x48x42 mm), nije potreban veliki radni prostor. Automatski se smanjuju dimenzije cjelokupnog stroja, smanjuje se potreban prostor za instalaciju stroja u pogonu (potrebna površina proizvodne hale) i konačno, snižena je i cijena samog stroja. Zbog toga su investicije manje, što je još jedan od najvažnijih kriterija.

Veličina serije utječe na isplativost kupnje jačeg i boljeg stroja. Ako su serije male, onda su manji strojevi pogodniji, no ako su serije veće onda je bolje kupiti jači i brži stroj koji će u kraćem vremenu i uz niže troškove moći obraditi veću količinu proizvoda. Kada je količina veća, cijena proizvoda je manja, što proizlazi iz manjih troškova proizvodnje. Kada su troškovi proizvodnje manji, premda je nabavna cijena stroja veća, stroj će biti više iskorišteniji, produktivnost će biti veća, pa će se na kraju takav stroj više isplatiti nego manji, slabiji i jeftiniji stroj.

Odabrani stroj treba omogućiti tokarenje, glodanje, skidanje srha, bušenje i narezivanje navoja (standardni CNC stroj), s obzirom na zahtjeve obrade odabranih proizvoda. Svaka operacija kod svakog proizvoda zahtjeva različiti alat, zato je broj alata koji stane u revolver glavu odabranog alatnog stroja vrlo važan kako bi se izbjeglo nepotrebno zaustavljanje te ručna i naknadna izmjena alata, odnosno njihovo postavljanje i programiranje u revolver.

Stezne naprave su vrlo bitne jer je obrada takva da se svaki proizvod mora zasebno stezati i otpuštati pa bi se trebalo voditi računa o skraćanju pomoćnog vremena koje se odnosi na stezanje i otpuštanje obratka. Također, dobra stezna naprava umanjuje mogućnost pogreške

pri stezanju, a time i nastanak greške na konačnom proizvodu. Materijali proizvoda su aluminijeve legure, koje su relativno nezatjevnih mehaničkih svojstava pa se svaka veća i neodgovarajuća sila stezanja odražava na kvalitetu proizvoda.

Aluminijeve legure u ovom slučaju dopuštaju korištenje strojeva manje snage (snagu obično određuju materijal i dimenzije obratka) što snižava nabavnu cijenu stroja. Stoga se mora dati na važnosti i odabiru optimalne snage stroja, jer, u slučaju da se odabere nepotrebna prevelika snaga, povećavaju se cijena, dimenzije i potrošnja energije.

Strojem se mora lako i jednostavno upravljati kako bi se izbjegla mogućnost ljudske pogreške te brza i jeftina prilagodba i edukacija novog radnika. Također, ovdje ulaze u obzir i ergonomske kriteriji, koji omogućuju radniku bolje uvjete za rad, što rezultira većom motiviranošću i, najvažnije, većom produktivnošću i kvalitetom samog proizvoda.

Kompatibilnost s CAM softverom odražava se na fleksibilnost stroja i omogućuje brzu prilagodbu novim proizvodima ili čak obavljanja nekih modifikacija na postojećim proizvodima.

Broj osi omogućuje lakše i brže manipuliranje alatom/obratkom (4 i 5 os) što rezultira kraćim vremenom izrade. Omogućuje i izvođenje kompliciranijih operacija što opet pridonosi fleksibilnosti samog stroja.

Konačno i najvažnije jest cijena samog stroja koja je u općem slučaju presudna. Cijena se u AHP metodu uvrštava kao kvantitativan kriterij. Zbog njene velike važnosti razmatra se kupnja rabljenih strojeva, ili čak izgradnja vlastitih (opširnije u poglavlju 5.7., odnosno 5.8.).

5.4. Odabir najbolje alternative

Kao alternative odabrano je nekoliko novih alatnih strojeva. Budući da se radi o proizvodima relativno malih dimenzija (do 100 mm), aluminijevim legurama te potrebom tokarenja, bušenja, narezivanja navoja i skidanja srha, odabiru se manji CNC obradni centri.

Odbrani su četverosni obradni centar EC-400 i VF1 američkog proizvođača HAAS (Slika 5.7. i Slika 5.8.), troosni obradni centar VMX10i (Slika 5.9.) i VMX24i (Slika 5.10.) i četveroosni obradni centar HMX500i (Slika 5.11.), njemačkog proizvođača Hurco. Usporedba njihovih specifikacija prikazana je u Tablici 2.

Kod odabira navedenih alternativa, uzele su se u obzir dimenzije radnog prostora, te na temelju njih su se odabrali strojevi iz kataloga proizvođača. Odabrani su strojevi koji spadaju u najmanju kategoriju tih proizvođača, jer oni u potpunosti zadovoljavaju navedene kriterije. EC-400, VF1, VMX10i i VMX24i relativno su sličnih karakteristika, te bi ih se moglo svrstati

u isti razred strojeva. HMX 500i horizontalni je obradni centar čije su tehničke karakteristike skoro pa dvostruko bolje od preostalih alternativa. On je odabran kako bi se pokazalo da se AHP metodom može riješiti slučaj kada se dobije da je neki stroj u svim pogledima bolji od drugih, no njegova je cijena prevelika.



Slika 5.7. HAAS EC-400 [8]



Slika 5.8. HAAS VF1 [8]



Slika 5.9. HURCO VMX10i [9]



Slika 5.10. HURCO VMX 24i [9]



Slika 5.11. HURCO HMX500i [9]

	HAAS EC-400	HAAS VF1	HURCO VMX 10i	HURCO VMX 24i	HURCO HMX 500
Dimenzije obradnog prostora (mm)	508x508x508	508x604x508	660x410x510	610x510x610	2000x500x500
Snaga (kW)	14,9	22,4	11	9	48
Nosivost stola (kg)	454	1361	340	1350	500
Broj alata	25	20	20	24	60
Broj osi	4	3	3	3	4
Maksimalni radni hod (m/min)	25,43	25,4	24/24/24	45/40/45	35/35/30
Maksimalni okret vretena (Nm)	102	122	74	95	183
Nabavna cijena (€)	125995	38995	70000	120000	180000

Tablica 2. Usporedba specifikacija alatnih strojeva [8], [9]

U Tablica 2. prikazana je usporedba odabranih alternativa, odnosno novih strojeva s obzirom na njihove najvažnije značajke. Podaci su dobiveni iz komercijalnih kataloga proizvođača. Upravo su tri kriteriji u AHP modelu uvršteni kao kvantitativni.

5.4.1.1. Ponderiranje alternativa

Alternativama su važnosti dodijeljene prema njihovim značajkama, prikazanih u Tablici 2. Izvor značajki su službeni katalogi proizvođača. U Tablici 2. su prikazane najvažnije značajke koje su vezane za najvažnije i najutjecajnije kriterije. Razlika između odabrana tri alatna stroja je očita. Objektivno gledano, ne uključujući u obzir kriterije i ishod AHP metode, vidljivo je kako je Hurco HMX 500 po samim karakteristikama najbolji. Najlošiji je Hurco VMX 10i, dok je HAAS EC-400 nešto bolji od oba VMX-a, no dovoljno je iza HMX-a. HAAS VF1 po generalnim karakteristikama bolji je od EC-400. No, kako najbolje tehničke karakteristike stroja nisu presudne za sam odabir, već je potrebno naći optimalno rješenje, potrebno je provesti AHP metodu te vidjeti koji se od ova tri stroja zapravo isplati nabaviti.

Za neke kriterije ne postoje točni podaci po kojim bi se ovi strojevi mogli usporediti, kao što su na primjer pad tržišne cijene, mogućnost zbrinjavanja ili emisije štetnih tvari tijekom proizvodnje. U tom su se slučaju alternative ponderirale na temelju njihove mase, gdje je stroj najmanje mase bio najpogodniji.

Također, kod ergonomske su se kriterija, osim komercijalnih podataka od strane proizvođača uzeli i u obzir dojmovi dosadašnjih korisnika izraženi na raznim internetskim forumima. Zbog relevantnosti takvih podataka uzelo se u obzir nekoliko različitih slučajeva u kojima je ishod, odnosno dojam samog korisnika, bio sličan. Dojmovi i iskustva korisnika djelomično se slažu s komercijalnim podacima, no bili su presudni kod odlučivanja koji je stroj bolje prilagođen korisniku te s kojim je lakše, brže i jednostavnije upravljati.

Kod parne usporedbe gdje nisu niti približno poznati točni podaci vrijedi sljedeći poredak:

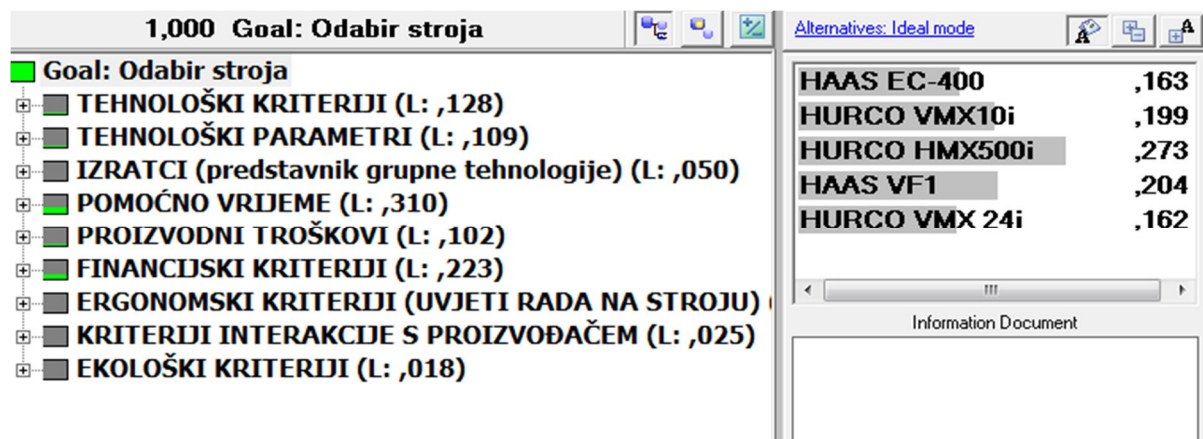
1. HMX 500i
2. VF1
3. EC-400
4. VMX 24i
5. VMX 10i,

gdje je brojem jedan označen najbolji stroj, s najvišim prioritetom, dok je s pet označen najlošiji stroj s najmanjim prioritetom.

Kvantitativni kriteriji (dimenzije obradnog prostora, snaga stroja, nosivost stola, broj alata, broj osi, maksimalna brzina (radni hod), maksimalni okret vretena i nabavna cijena) računati su primjenom STEP funkcije.

5.5. Rezultati AHP metode u Expert Choiceu

Kao optimalan rezultat dobiven AHP metodom je Hurco HMX 500, što se poklapa s osnovnom pretpostavkom da ima najpovoljnije karakteristike. Drugi izbor je VF1, a treći je VMX 10i, četvrti je EC-400, a peti VMX 24i. Iz dobivenih je rezultata vidljivo kako drugi izbor ne zaostaje puno za prvim, te je zato potrebno napraviti analizu benefit/troškovi (opisano u Prilogu I.) kako bi se konačno odlučilo isplati li se kupiti slabiji i jeftiniji stroj ili skuplji i jači, s obzirom na potrebe odabranog proizvodnog programa.



Slika 5.12. Rezultati cilja

Iz Slika 5.12. vidljivo je kako vektor prioriteta alternativa ima vrijednosti 0,273 za HMX, 0,204 za VF1, 0,199 za VMX 10i, 0,163 za EC-400 i 0,162 za VMX 24i. Taj će se vektor koristiti kod računanja omjera benefita i troškova.

Rezultati su opravdali prijašnju pretpostavku, da će HMX biti najbolji izbor, no vidljivo je kako je AHP metoda pomogla pri odabiru između ostalih alternativa, strojeva koji su relativno sličnih karakteristika.

5.5.1. Konzistentnost

Kako bi model bio valjan, a time i sami rezultati, potrebno je da konzistentnost bude manja od 10%. [10]



Slika 5.13. Konzistentnost alternativa

Iz Slika 5.13. vidljivo je kako je konzistentnost 4% što opravdava dobiven rezultat i čini ga valjanim. Proračun konzistentnosti i adekvatne vrijednosti opisane su u Prilogu I.

5.5.2. Rezultati s obzirom na najvažnije kriterije

Od samih kriterija, najvažniji su: **Tehnološki kriteriji**, **Tehnološki parametri**, **Pomoćno vrijeme**, **Proizvodni troškovi** te **Financijski kriteriji**. Navedeni su kriteriji ponderirani po sljedećem redoslijedu (od najvažnijeg prema manje važnom): Pomoćno vrijeme, Financijski kriteriji, Tehnološki parametri, Tehnološki kriteriji i Proizvodni troškovi. Proizvodni troškovi su jedan od najvažnijih kriterija, no s obzirom na potrebe, procjena je kako tehnološki parametri i tehnološki kriteriji sadrže neke važnije potkriterije. Također, ova situacija dokazuje kako postoji mnogo različitih mogućnosti, stoga svaki korisnik pri ovakvom investicijskom projektu prema vlastitim potrebama i iskustvu procjenjuje važnost pojedinih kriterija. Upravo ovdje dolazi u pitanje prednost ili nedostatak AHP metode, prisustvo ljudskog faktora i subjektivnosti.

Potrebno je sagledati kako su rangirane alternative s obzirom na te kriterije (Slika 5.14).

Alternative	Score
HAAS EC-400	,144
HURCO VMX10i	,080
HURCO HMX500i	,409
HAAS VF1	,244
HURCO VMX 24i	,123

Slika 5.14. Alternative s obzirom na tehnološke kriterije

Budući da su tehnološki kriteriji isključivo vezani za same tehničke karakteristike stroja, bilo je za očekivati da će ovdje HMX biti ispred svih (Slika 5.14.). S obzirom na četiri osi, daleko veće dimenzije obradnog prostora i duplo veću snagu od ostala dva kandidata, HMX je s razlogom prvi odabir po ovom kriteriju.

Alternative	Score
HAAS EC-400	,170
HURCO VMX10i	,130
HURCO HMX500i	,340
HAAS VF1	,210
HURCO VMX 24i	,150

Slika 5.15. Alternative s obzirom na tehnološke parametre

Kao i kod tehnoloških kriterija, i tehnološki su parametri (Slika 5.15.) vezani za tehničke karakteristike stroja koje su dane od strane proizvođača. HMX postiže puno veću maksimalnu brzinu, lakše ga je automatizirati, ima bolje mogućnosti za spremište priprema te bolji SHIP i odvodnju odvojene čestice. No, što se samih dimenzija stroja i potrebne infrastrukture tiče, tu je najbolji odabir VMX kao najmanji i najslabiji. Ti su kriteriji premalo utjecajni, pa ipak na kraju HMX prevlada.

Alternative	Score
HAAS EC-400	,167
HURCO VMX10i	,116
HURCO HMX500i	,392
HAAS VF1	,200
HURCO VMX 24i	,125

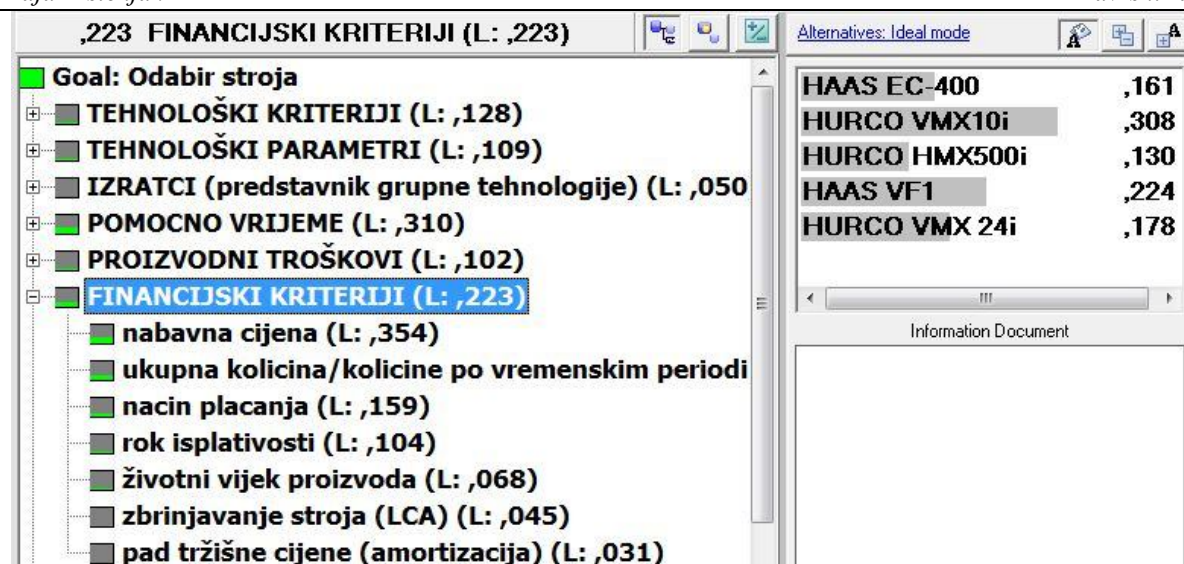
Slika 5.16. Alternative s obzirom na pomoćno vrijeme

Kriterij Pomoćno vrijeme također većinom obuhvaća samo tehničke karakteristike po kojima je, još jednom, HMX optimalan izbor (Slika 5.16.). Velika se razlika vidi u činjenici kako VMX i VF1 imaju samo tri, dok EC-400 i HMX imaju četiri osi stroja, a taj je potkriterij prilično važan. Također je važan potkriterij broj alata u revolveru gdje HMX ima duplo više mjesta od preostala četiri, što opet omogućuje i bolju izmjenu alata. Korištenje standardnih naprava, posebnih naprava, 4. i 5. os za stezanje obratka, korištenje protuvretena, dobave šipki, paleta, skraćuje pomoćna vremena, povećava produktivnost i skraćuje rok isporuke. Sve navedeno omogućava veću konkurentnost tvrtke na tržištu.

,102 PROIZVODNI TROŠKOVI (L: ,102)		Alternatives: Ideal mode	
Goal: Odabir stroja		HAAS EC-400	,150
TEHNOLOŠKI KRITERIJI (L: ,128)		HURCO VMX10i	,360
TEHNOLOŠKI PARAMETRI (L: ,109)		HURCO HMX500i	,120
IZRATCI (predstavnik grupne tehnologije) (L: ,050)		HAAS VF1	,107
POMOCNO VRIJEME (L: ,310)		HURCO VMX 24i	,263
PROIZVODNI TROŠKOVI (L: ,102)			
trošak održavanja (L: ,297)			
trošak po satu upotrebe (L: ,540)			
tehnološko vrijeme (L: ,163)			

Slika 5.17. Alternative s obzirom na proizvodne troškove

Kod kriterija Proizvodni troškovi priča se mijenja u korist VMX-a koji je kao najslabiji i najmanji ujedno i najjeftiniji, što je u ovom slučaju prioritet (Slika 5.17.). S obzirom na dimenzije i potrebnu količinu energije, troškovi njegova održavanja i rada su daleko manji od velikog HMX-a. Upravo je zato ovaj stroj prema ovom kriteriju optimalan izbor. Cijenu samog proizvoda određuje tržište, no razlika između troškova i cijene je dobit, stoga je kriterij proizvodnih troškova jako važan za poslovanje firme.




Slika 5.18. Alternative s obzirom na financijske kriterije

Ista je stvar i kod financijskih kriterija po kojima je VMX 10i optimalan izbor (Slika 5.18.). Budući da je nabavna cijena zapravo i najznačajniji kriterij u cijeloj priči, ona će još jednom biti uključena u izbor pri izračunu omjera dobivenih benefita i troškova na temelju kojeg će se donijeti i konačna odluka. Način plaćanja je kod svih strojeva jednak, odnosno, moguće ih je platiti kreditom, *leasingom* ili gotovinom. Potkriteriji zbrinjavanja stroja i pada tržišne cijene uzeti ponderirani su s obzirom na masu svakog stroja, jer na tržištu rabljenih strojeva se upravo po tome i formira prodajna cijena (opširnije u 5.7.). Također, što je stroj veći i kompleksniji teže ga je zbrinuti.

5.5.3. Graf osjetljivosti

Rezultati su prikazani na grafu osjetljivosti (Slika 5.19.)




Slika 5.19. Graf osjetljivosti cilja – primarni

Na Slika 5.19. prikazan je graf osjetljivosti s rezultatima AHP modela. Ovdje su još jednom prikazani prethodno objašnjeni rezultati. Vidljivo je kako je HMX 500i najbolji što se tehničkih kriterija tiče dok je VMX 10i. najbolji što se financijskih kriterija tiče. Također, VMX 10i je najbolji prema ekološkim kriterijima. Preostale su alternative su u sredini, no iz grafa se mogu primijetiti vrlo dobre tehničke karakteristike stroja VF1. U konačnim su rezultatima VF1 i VMX 10i vrlo blizu, su rezultati EC-400 i VMX 24i gotovo identični.

Budući ga graf osjetljivosti omogućuje provedbu „what-if“ analize, promotrit će se utjecaj jačanja udjela pojedinih kriterija na cilj.

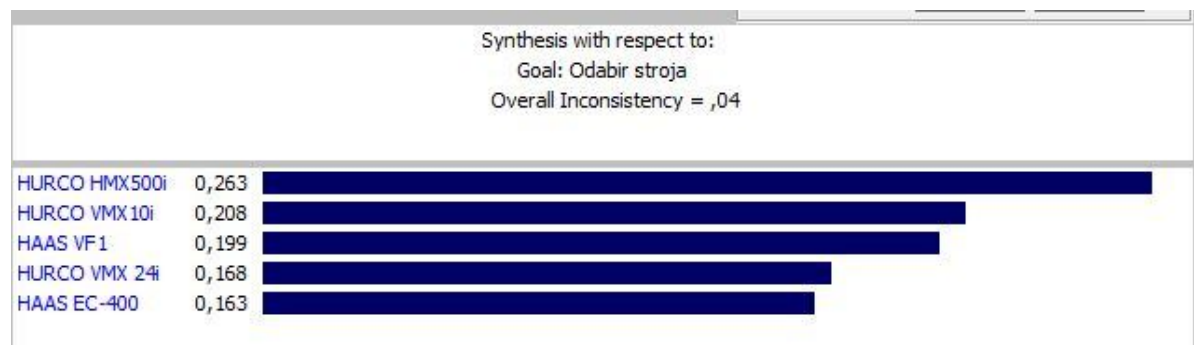
Budući da je HMX puno bolji u tehničkim kriterijima od preostala dva, potrebno je sagledati što će se dogoditi ako se poveća utjecaj financijskih kriterija (Slika 5.20.)



Slika 5.20. Graf osjetljivosti s obzirom s najvećim udjelom financijskih kriterija

Iz Slika 5.20. vidljivo je kako je VMX 10i došao na prvo mjesto tek kada se povećao utjecaj financijskih kriterija na konačni cilj na oko 50%. To je ipak preveliki utjecaj te su sada zanemareni, odnosno podcijenjeni ostali kriteriji. Budući da je nabavna cijena samo potkriterij, nije potrebno povećati udio financijskih kriterija već samo napravi omjer benefita i troškova.

AHP model izrađen je uz pretpostavku izrade većih serija. Promjenom kriterija „veličina serije“ u korist manjim serijama dobivaju se rezultati prikazani na Slika 5.21.



Slika 5.21. Rezultati cilja za manju seriju

Iz Slika 5.21. vidljivo je kako je još uvijek Hurco HMX 500i prvi izbor i kada se radi o proizvodnji manjih serija. No, zanimljiv je drugi odabir, VMX10i za koji se sada ispostavilo da je bolja alternativa od VF1. Također, došlo je i do zamjene mjesta EC-400 i VMX 24i, što govori o velikom utjecaju kriterija „veličina serije“ na konačni odabir“.

5.6. Konačni odabir

Kao što je već navedeno, za konačni je odabir potrebno provesti proračun Benefit/Troškovi. Benefit su vrijednosti iz vektora cilja (Slika 5.12.) dok su troškovi normalizirane vrijednosti cijena strojeva.

Cijene HAAS strojeva su poznate i na internetu navedene. Za EC-400 početna cijena je 125 995 eura, za VF1 početna cijena je 38 995 eura. Cijene HURCO strojeva dostupne isključivo na upit, stoga su uzete okvirne vrijednosti, s obzirom na njihovu veličinu, snagu, funkcije i komercijalnu skupinu definiranu od samog proizvođača. Također, cijene HURCO strojeva definirane su prema podacima o okvirnim cijenama strojeva te serije proizvođača. Proračun se vrši tako da se cijene strojeva normaliziraju te se podijeli vrijednost iz vektora funkcije cilja. Vrijednosti (prikazani na Slika 5.12., postupak detaljno opisan u Prilogu I.) u vektoru funkcije cilja su benefiti (B). Postupak je prikazan u Tablici 3.

	Cijena (eur)	Normalizirana cijena -T	Benefit - B	B/T
VMX 10i	70000	$70000/534990=0,131$	0,193	1,473
VMX 24i	120000	$120000/534990=0,224$	0,160	0,714
EC-400	125995	$125995/534990=0,236$	0,163	0,691
VF1	38995	$38995/534990=0,073$	0,206	2,822
HMX 500i	180000	$180000/534990=0,336$	0,278	0,827
UKUPNO	534990			

Tablica 3. Proračun B/T za veliku serije

Iz Tablica 3. vidljivo je kako je najveći B/T omjer ima VF1. Iz tog se razloga upravo ta alternativa preporuča kao konačan odabir za kupnju. Također, treba se uzeti u obzir kako je ovo početna cijena svih proizvoda te u nju nije uključena dodatna oprema koju je moguće naručiti. Također, cijena se alatnih strojeva u velikoj većini slučajeva formira pregovaranjem i direktnim dogovorom između proizvođača i kupca. U formiranje ulazi i faktor količine naručenih strojeva, dosadašnja suradnja, značaj i veličina kupca kao takvog, itd.

Proračun omjera benefita i troškova u slučaju izrade manjih serija je prikazan u Tablici 4.

	Cijena (eur)	Normalizirana cijena -T	Benefit - B	B/T
VMX 10i	70000	$70000/534990=0,131$	0,208	1,588
VMX 24i	120000	$120000/534990=0,224$	0,168	0,75
EC-400	125995	$125995/534990=0,236$	0,163	0,691
VF1	38995	$38995/534990=0,073$	0,199	2,726
HMX 500i	180000	$180000/534990=0,336$	0,263	0,783
UKUPNO	534990			

Tablica 4. Proračun B/T za malu seriju

Još jednom, najbolji izbor je VF1, upravo zbog najpovoljnijeg omjera cijene i performansi koje nudi. Da je njegova cijena viša, cijeli bi problem vjerojatno konvergirao k drugom izboru, VMX 10i.

5.7. Odabir rabljenih strojeva

Poduzeće *Metal Product* u svoj je strojni park uvrstilo i nekoliko rabljenih strojeva. Kupnja se rabljenih strojeva čini kao vrlo privlačan potez jer su na tržištu lako dostupni, a prije svega u prosjeku su sedam puta jeftiniji od novih alatnih strojeva.

Kupnjom rabljenog stroja ulazi se u veliki rizik jer su ti strojevi većinom bez garancije (ili je garancija manja od novo nabavljenih) te ne postoji nikakva podrška od strane dobavljača.

No, najveća je prednost upravo cijena i činjenica da se investicija isplati u vrlo kratkom vremenu.

Kriteriji pri odabiru rabljenih strojeva u najvećoj se mjeri odnose na tehničku ispravnost. Često se dobavljačima ne može vjerovati kad je riječ o odrađenim satima i uvjetima rada u kojima je stroj proizvodio u prošlom „proizvodnom životu“. Zato se stupa u kontakt s ovlaštenim serviserom za proizvođača stroja koji detaljno pregledava stroj i utvrđuje njegovo stanje, a ispravnost podataka garantira sklopljeni Ugovor.

Najvažnije parametre koje je potrebno utvrditi pregledom jesu:

- Broj radnih sati, u koje su uključeni sati rada (vrtnje vretena) i rad u *stand by* načinu rada.
- Ispravnost i istrošenost vretena.
- Mehanička ispravnost strojnih dijelova
 - Vretena
 - Kliznih vodicica

- Ležajeva
- Kompletne mehanike i elektronike stroja

Cijena rabljenog stroja formira se po kilogramu, a kupuju se od pouzdanih dobavljača te u većini slučajeva osobna poznanstva mogu presuditi hoće li dobavljač ponuditi pouzdan ili loš stroj.

Odluku o odabiru alatnih strojeva može se donijeti i AHP metodom, no, budući da vrlo rijetko postoji sigurnost za dodjeljivanje važnosti određenoj alternativni, rezultati u nekim slučajevima mogu varati.

Na tržištu je velika ponuda rabljenih strojeva koji su u prosjeku duplo jeftiniji od novih. Pretraživanjem internetske ponude (točnije, ponude na Internet prodajnom servisu *E-Bay*, zbog detaljnosti podataka), kao primjer su uzeta tri alatna stroja proizvođača HAAS i jedan proizvođača Hurco.



Slika 5.22. HAAS VF-2 rabljeni, slika iz oglasa [11]

Prvi primjer u ponudi je HAAS VF-2 obradni centar. (Slika 5.22.) Njegove karakteristike uključuju tri osi i priključak za četvrtu i petu os, maksimalan okret vretena od 7000 rpm i snagu 11 kW. Godište izrade je 1997., a cijena 25 570 eura.



Slika 5.23. HAAS VF-2 rabljeni – slika iz oglasa [12]

Drugi primjer je HAAS VF-2 obradni centar (Slika 5.23.). Njegove karakteristike uključuju četiri osi, dimenzije radnog prostora 762 x 406 x 508 mm, maksimalan okret vretena od 12 000 rpm, 24+1 mjesto za alat i snagu 30 kW. Godište izrade je 2007., a cijena 38 800 eura.



Slika 5.24. HAAS VF-3 rabljeni – slika iz oglasa [13]

Treći primjer je HAAS VF-3 obradni centar (Slika 5.24.). Njegove karakteristike uključuju četiri osi, dimenzije radnog prostora 1016 x 508 x 635 mm, maksimalan okret vretena od 7500 rpm, 20 mjesta za alat i snagu 20 kW. Godište izrade je 1998., a cijena 68 700 eura.



Slika 5.25. Hurco VM1 rabljeni [14]

Četvrti primjer u ponudi je Hurco VM1 vertikalni obradni centar. (Slika 5.25.) Njegove karakteristike uključuju tri osi, maksimalan okret vretena od 8000 rpm i snagu 8,5 kW. Godište izrade je 2004., a cijena 28 719 eura.

Iz navedenih podataka je vidljivo kako cijena ne mora nužno ovisiti o godištu i karakteristikama samog stroja. Generalno je prihvaćeno kako se cijena rabljenih strojeva formira po kilogramu, no prodavači sami formiraju naknadno vlastite cijene u dogovoru s kupcem. Za sve od navedenih primjera piše kako su u dobrom stanju te da su moguće samo manje kozmetičke greške te da tehnički dio još uvijek jako dobro radi. Također, neki trgovci na internet postavljaju video spotove rada strojeva. Mnogim strojevima cijena je isključivo na upit, stoga ju je sigurno moguće još spustiti.

Budući da ovdje postoji velika doza rizika u vjerodostojnosti podataka, iskusna poduzeća imaju provjerene dobavljače koji kvalitetu strojeva mogu garantirati na prethodno opisan način.

Jedina primamljiva stvar kod rabljenih strojeva je njihova cijena, koje je, s obzirom na njihove karakteristike skoro pa dvostruko manja od novih strojeva. Također, ti su strojevi odmah dostupni.

5.7.1. Prednosti i nedostaci rabljenih strojeva

Neke od prednosti rabljenih alatnih strojeva su sljedeće:

- Niska cijena. Nabavna cijena u prosjeku je dvostruko manja od nabavne cijene novih strojeva.
- Dostupnost. Pri kupnji novih strojeva potrebno je čekati na dostavu određenog vremenskog perioda jer je u vrijeme isporuke potrebno uključiti i vrijeme potrebno za njihovu izradu. Rabljeni su strojevi dostupni odmah.
- Amortizacija. Rabljeni se strojevi amortiziraju u puno kraćem vremenskom periodu od novih strojeva, prvenstveno zbog niže nabavne cijene. To je automatski odražava i na cijenu samog proizvoda koja može biti niža pa je tako poduzeće konkurentnije na tržištu.

Nedostaci rabljenih strojeva su sljedeći:

- Upitna kvaliteta i veliki rizik. Nabava rabljenih strojeva predstavlja određeni rizik za kupca. Teško je na temelju specifikacija prodavača sa sigurnošću tvrditi da je stanje stroja kako je opisano. Potrebno je imati vrlo dobre izvore kako bi se uvjerali u stvarno stanje stroja. Ukoliko dođe do kvarova financijski gubici su veliki. Nepravilno funkcioniranje stroja može izazvati i lošiju kvalitetu proizvoda.
- Nema garancije. Novi alatni strojevi dolaze s garancijom proizvođača koja omogućuje besplatan servis ukoliko dođe do nekih grešaka ili kvarova bez dodatnih troškova.
- Nema edukacije i podrške. Proizvođači novih strojeva u paket uključuju program edukacije zaposlenika i podršku pri korištenju. Kod nabave rabljenih strojeva toga nema te se zaposlenici moraju sami educirati i shvatiti način na koji alatni stroj radi. To zahtjeva mnogo vremena te su moguće greške pri korištenju.

- Umijeće pregovaranja. Cijena se formira isključivo u direktnom dogovoru s prodavačem, stoga dolaze do izražaja komunikacijske sposobnosti kupca koji uz malo spretnosti uspije formirati cijenu koja njemu odgovara.
- Intuicija pri donošenju odluka. Vezano i za prethodno navedeno umijeće pregovaranja, kupac sam ponekad intuitivno donosi odluke, što je opet ovisno i o prodavaču, i njegovom umijeću predstavljanja vlastitog proizvoda. Ponekad intuicija može prevariti te odluka koju pojedinac donese može biti kriva i imati određene posljedice.

5.8. Gradnja vlastitih strojeva

Kao treća opcija pri odabiru alatnog stroja nalaže se gradnja vlastitih strojeva, što je bio slučaj u poduzeću *Metal Product* i iskazao se kao vrlo dobra i isplativa solucija.

Vlastiti je stroj u potpunosti prilagođen proizvodnim potrebama poduzeća za određeni proizvod ili skupinu proizvoda. Radi se o već postojećem alatnom stroju koji je zastario ili njegova funkcija ne ispunjava u potpunosti zahtjeve proizvodnog postupka. Stari se, amortiziran, alatni stroj prenamjenjuje te se iskorištavaju njegovi dijelovi ili se nabavljaju novi. Zanimljiva je činjenica da, prema podacima poduzeća *Metal Product*, gradnja vlastitih strojeva predstavlja *čak sedam puta manji trošak od nabave novog stroja*. Bilo da se radi o samoj prilagodbi postojećeg stroja, gradnji potpuno novog stroja ili spajanju dva stroja u jedan, ova solucija zvuči vrlo primamljivo, bar što se financijskog dijela tiče. Također, dobiva se *alatni stroj u potpunosti prilagođen potrebama vlastite proizvodnje*. No, ova opcija, prije svega, zahtjeva jednu vrlo važnu komponentu, a to je ljudsko znanje. Potrebno je imati osoblje ili zaposliti stručnu osobu koja bi bila sposobna projektirati novi stroj. Ovdje se ne radi samo o tehničkom znanju (koje također mora biti vrlo izraženo i kvalitetno) već i o poznavanju rada poduzeća, prepoznavanja potrebe proizvodnje te mogućnosti okvirnog predviđanja budućih potreba. Važan je timski rad i međusobna suradnja. Vrlo često točan ishod i funkcionalnost vlastitog stroja nije poznat pa se mogući nedostaci njegova konačnog ishoda rješavaju isključivom metodom pokušaja i pogrešaka. Ukoliko će stroj raditi i biti koristan, to će biti zadovoljavajuće, no, ukoliko je stroj loš i nefunkcionalan radi se na njegovom preoblikovanju i poboljšanju. Gradnja vlastitih strojeva zato također unosi određenu dozu rizika u poslovanje. Takav je stroj intelektualno vlasništvo poduzeća i kao takav je neprocjenjive vrijednosti.

5.8.1. Prednosti i nedostaci gradnje vlastitih strojeva.

Neke od prednosti gradnje vlastitih strojeva su sljedeće:

- Prilagođenost vlastitim potrebama. Takvi su strojevi u potpunosti prilagođeni potrebama proizvodnog programa te su velika konkurentska prednost jer omogućuju jednostavnu i jeftiniju proizvodnju dijelova iz vlastitog proizvodnog programa.
- Niža cijena. Gradnja vlastitih strojeva je u nekim slučajevima jeftinija od nabavke i rabljenih strojeva. Iskustvo *Metal Producta* pokazalo je kako je izrada vlastitih strojeva do *sedam puta jeftinija od nabavke novih strojeva*.

Nedostaci gradnje vlastitih strojeva su sljedeći:

- Dugotrajan razvoj i izgradnja. Za vlastiti alatni stroj prvo je potrebno iskazati potrebu, zatim ga projektirati, konstruirati i razviti na temelju zahtjeva proizvodnog programa. Također, potrebno je nabaviti sve rezervne dijelove, od raznih dobavljača. Također, potrebno ih je sve uskladiti kako bi izgradnja dobro funkcionirala bez raznih poteškoća.
- Znanje kao najvažniji resurs. Zaposlenici su ti koji najbolje poznaju proizvodni proces i njegove zahtjeve te bi oni trebali posjedovati znanje o tome kakav bi vlastiti stroj trebao biti. Ukoliko nemaju to znanje, potrebni su dodatni financijski troškovi pri zapošljavanju vanjskih suradnika u tom projektu. Bitan je timski rad i suradnja između radnika i menadžmenta.
- Upitne karakteristike finalnog proizvoda. Jednom kada se vlastiti stroj konstruira i izradi, ne može se u potpunosti garantirati da će sve jako dobro funkcionirati. Također, upitno je hoće li takav stroj biti fleksibilan za potrebe prilagodbe novim proizvodima.

6. ISPLATIVOST ODABRANOG STROJA

U situacijama odabira alatnog stroja u praksi se još uvijek rijetko koristi AHP metoda. Strojevi se odabiru međusobnom usporedbom troškova i performansi, bez detaljnog matematičkog proračuna.

Isplativost odabira (u ovom slučaju to je HAAS VF1) računa se na temelju planirane količine proizvoda, satima rada stroja i cijene sata rada.

Isplativost će se računati na realnom primjeru iz poduzeća Metal Product i prema njihovim podacima, prikazanim u Tablica 5.

	Količina (kom/mjesec)	Planirano vrijeme obrade (h)
Tijelo MP1030	1000	12,6
Stezaljka odvoda prednapona	1000	9,4
Kučište V-kleme	1000	5,4
Kučište stezaljke	1000	22,3
Stopnica Al	1000	9,2
UKUPNO:	5000	58,9

Tablica 5. Podaci o proizvodnji [15]

Cijena stroja je 38995 eura. To je polazna cijena stroja. Ukoliko se postigne dogovor s prodavačem i na stroj se nadogradi još neka dodatna oprema, može se pretpostaviti da će konačna nabavna cijena biti 42 000 eura. Ukoliko se radi 365 dana u godini, u dvije smjene, to je ukupno 5840 sati rada godišnje. Iz toga se zaključuje kako će cijena radnog sata stroja biti 7,19 eura. Ukoliko se radi u tri smjene, ukupno 8760 sati godišnje, tada je cijena stroja 4,79 eura po satu, samo za otplatu stroja. Ukoliko se radi oko 256 dana u godini, što je okvirni prosjek bez uključenih vikenda i praznika, u dvije smjene, tada cijena radnog sata raste na 10,25 eura. Ta se cijena odnosi isključivo na trošak otplate stroja. Ona raste kada se u nju uključe ostali troškovi – troškovi rada, režija, menadžmenta, indirektnog rada, marketinga, financija, konstrukcije, održavanja... Cijena radnog sata stroja, uz uključene sve navedene troškove, prema podacima iz Metal Producta je oko 20 eura, s time da oni koriste rabljene strojeve. Budući da se ovdje radi o onom stroju, te ukoliko se na cijenu stroja po satu dodaju

cijena rada, energije i drugih troškova, sat rada stroja, u dvije smjene može narasti na oko 24 eura, ukoliko se radi o boljem i novom stroju. Ukoliko je cijena jednog proizvoda 3 eura, da bi se stroj isplatio, potrebno je izraditi minimalno 8 proizvoda na sat. Stoga, ako je stroj bolji, ako su tehnološka, pomoćna i pripremno-završna vremena kraća, moguće je u satu napraviti više proizvoda. Iz navedenog se može zaključiti kako su zato ponekad skuplji strojevi i isplativiji, jer, premda je trošak veći, njihove performanse omogućavaju izradu više komada u jedinici vremena. Također, ovdje je uzeta u obzir idealna situacijama u kojoj je stroj u stalnom pogonu. U praksi to vrlo često nije slučaj.

Radom u dvije smjene, u mjesecu s prosječno 22 radna dana i 352 radna sata, bilo bi potrebno izraditi minimalno 2816 izradaka kako bi se stroj isplatio. U ovom je primjeru potrebno napraviti 5000 izradaka, što znači da je potrebno izraditi 15 izradaka na sat te da će kapaciteti biti popunjeni, a jedan bi se stroj tako otplatio za jednu godinu, pod uvjetom da se svi izradci rade na tom stroju.

Potrebno je razmotriti može li stroj postići produktivnost od 15 izradaka na sat. Prosječno vrijeme obrade jednog komada je 0,7068 minuta, što je 42,41 sekunda, to znači da se, teorijski u jedan sat može obraditi 84 komada. Budući da je samo 15 komada potrebno da se kapaciteti popune, a samo 8 da bi se stroj isplatio, ovo dovodi do zaključka kako će se uz povećanu produktivnost stroj moći brže otplatiti. Ukoliko se naručuje veći broj strojeva, rok isplativosti se produljuje, ako količine proizvoda ostanu konstantne.

7. PRIMJENJIVOST METODE U REALNOJ PROIZVODNJI

Činjenica je da se ova metoda u ovakvim situacijama u pravilu koristi jako rijetko ili se uopće ne koristi. Budući da je nabava alatnih strojeva zahtjevan financijski poduhvat, njihovo razmatranje AHP modelom i više je nego adekvatno. Osim korištenja AHP metode pri nabavi novih strojeva, moguće je i razmatrati primjenu metode u sklopu planiranja tehnološkog procesa, odnosno donošenja odluke između strojeva iz strojnog parka. Ovdje se također AHP metoda rijetko koristi. Razlog tome je što postoje već uhodani sustavi za upravljanje i planiranje proizvodnje koji su jednostavni i brzi za primjenu. No, postoje slučajevi u kojima bi ova metoda bila itekako primjenjiva. Budući da se danas teži k što većoj fleksibilnosti i prilagodbi kupcu, poduzeće bi se moglo naći u situaciji da treba proizvesti veliku količinu različitih proizvoda. Budući da je cilj minimizirati troškove, čime se automatski povećava dobit jer se cijena proizvoda gleda kao fiksna i definirana od strane kupca, vrlo je bitno da ti proizvodi budu obrađeni na što je moguće adekvatnijim strojevima. Također, ista se stvar dešava kod poduzeća s izrazito velikim strojnim parkom kada je potrebno odabrati na kojem će se stroju obrađivati pojedini dio. Stoga se AHP metoda, osim u opisanoj situaciji nabavke novih strojeva može koristiti i situacijama odabira strojeva iz vlastitog strojnog parka, u smislu projektiranja tehnološkog procesa.

8. ZAKLJUČAK

Odluka o nabavi alatnih strojeva složena je i povlači za sobom mnoge posljedice. One mogu biti pozitivne ili negativne. Naravno, svako poduzeće teži pozitivnim posljedicama te budućem poslovanju sa što većim dobitkom. Kako bi odluka bila što bolja, a proces što objektivniji potrebno je koristiti sustave za potporu pri donošenju odluke. Također, AHP metoda jedna je od najboljih u tim situacijama. Njeno korištenje brzo je i jednostavno putem programa *Expert Choice* koji daje zadovoljavajuće rezultate. Kako su financijski kriteriji danas najvažniji, a *Expert Choiceom* je dobiven rezultat s najboljim tehničkim kriterijima, potrebno je provesti izračun omjera benefita i troškova kako bi se donijela konačna i ispravna odluka. Pitanje koje se postavlja za daljnje istraživanje je jesu li obuhvaćeni svi potrebni kriteriji te kako znati jesu li oni dovoljno dobro postavljeni.

Također, u ovakvim se situacijama, osim novih, nudi mogućnost odabira rabljenih ili gradnje vlastitih strojeva. Novi strojevi su najsigurniji i proizvođač garantira za njegove karakteristike i rad te u slučaju nepravilnosti ili kvarova poduzeće nema nikakvih dodatnih troškova. Kupovina rabljenih strojeva povlači za sobom veliki rizik, no cijena je puno niža i ako se pokaže da je rabljeni stroj dobar i zadovoljava sve zahtjeve proizvoda i proizvodnog procesa, tada je to najbolji izbor za manja poduzeća. Gradnja vlastitih strojeva još je povoljnija opcija od kupovine rabljenih strojeva, no za to je potreban najskuplji i najvredniji resurs – znanje.

Finalno, za ozbiljna i velika poduzeća, te ona gdje se zahtijevaju složenije obrade te veća preciznost i kvaliteta proizvoda preporučljiva je kupnja novih alatnih strojeva. Rabljeni i vlastiti alatni strojevi izvrsna su, no istovremeno i vrlo riskantna prilika za srednja i manja poduzeća.

LITERATURA

- [1] Decision Support Systems Resources. <http://dssresources.com/> (6.1.2015.)
- [2] Begićević, N.: Doktorska dizertacija: Višekriterijalni modeli odlučivanja u strateškom planiranju uvođenja e-učenja. FOI. Varaždin, 2008.
- [3] Lisjak, Dragutin. Održavanje. Održavanje. Fakultet strojarstva i brodogradnje. Zagreb, studeni 2014.
- [4] Cerovšek, K.: Diplomski rad: Odabir alatnih strojeva u projektiranju tehnoloških procesa. FSB. Zagreb, 2014.
- [5] Expert Choice 11.5. programska podrška korisnicima
- [6] Expert Choice, <http://expertchoice.com/> (6.1.2015.)
- [7] Povijest firme. http://www.metal-product.hr/hr/o_nama/povijest_firme (6.1.2015.)
- [8] HAAS www.haascnc.com (21.2.2015.)
- [9] HURCO www.hurco.com (21.2.2015.)
- [10] Saaty, Thomas: Decision making with the analytic hierarchy process. Int.J. Services Sciences, Vol. 1, No. 1, 2008.
- [11] E-Bay http://www.ebay.com/itm/1997-Haas-VF-2-CNC-Machining-Center-/251680382843?pt=LH_DefaultDomain_0&hash=item3a9951df7b (2.2.2015.)
- [12] Machinio <http://www.machinio.com/listings/6311763-Used-2004-HURCO-VM1-MACHINING-CENTER-VERTICAL-MQ-010301-in-United-States> (2.2.2015.)
- [13] E-Bay <http://www.ebay.com/itm/HAAS-VF-3-CNC-Vertical-Machining-Center-Mill-CT40-4020-Gear-Box-4th-ready-Rigid-/261527225052> (18.1.2015.)
- [14] Quality Used CNC & Metalworking Machine Tools, <http://www.meridianmachinery.com/emailpage.htm> (21.2.2015.)
- [15] Dobiveni podaci tvrtke Metal Product

PRILOZI

- I. AHP metoda – primjer i opis postupka
- II. CD-R disk

PRILOG I: AHP metoda – primjer i opis postupka

U Prilogu I. bit će opisan matematički postupak AHP metode baziran na jednostavnom primjeru. Na isti način radi u program *Expert Choice*.

Analitički hijerarhijski proces (AHP) rješava se u četiri faze [3]:

0. Faza – strukturiranje problema – odredi se cilj za koji se odrede kriteriji te alternative.
1. Faza – određivanje najznačajnijeg kriterija – faza u kojoj se kriteriji uspoređuju u parovima prema međusobnim prioritetima.
2. Faza – određivanje najznačajnije alternative – faza u kojoj se alternative uspoređuju u parovima prema međusobnim prioritetima za svaki postavljeni kriterij.
3. Faza – određivanje konačnog rješenja (cilja) – na temelju prethodna dva koraka određuje se najbolje rješenje.

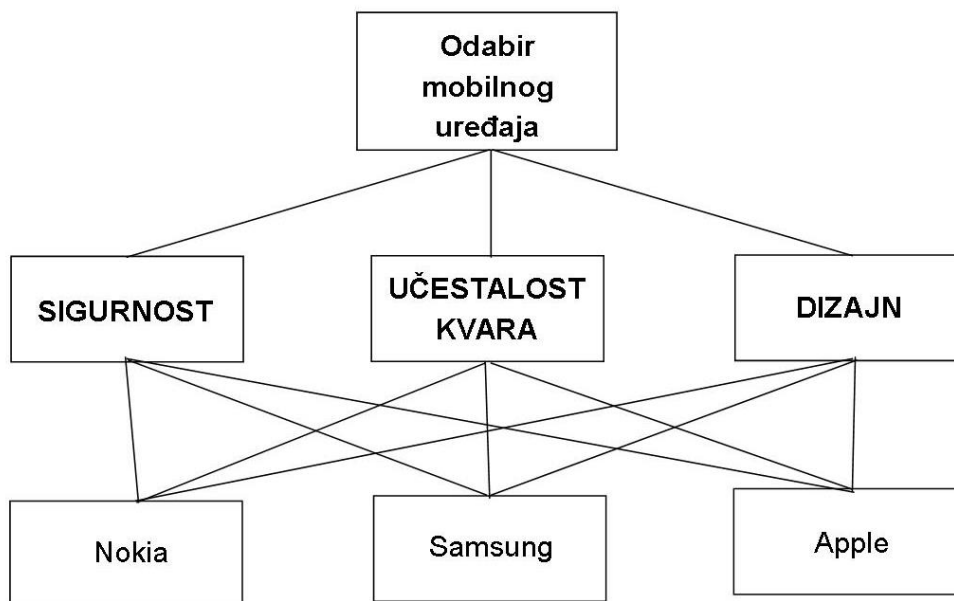
Kao primjer funkcioniranja i provedbe matematičkog modela AHP metode koristit će se slučaj odabira mobilnog uređaja na temelju tri kriterija:

- sigurnost
- učestalost kvara
- dizajn

Kao alternative odabrat će se tri različita proizvođača:

- *Nokia*
- *Samsung*
- *Apple*

Struktura problema prikazana je na Slika 26.



Slika 26. Struktura problema (primjer)

8.1. 1. Faza – određivanje najznačajnijeg kriterija

Kriteriji se međusobno vrednuju i uspoređuju u parovima pomoću Saatyjeve skale. Saatyjeva skala sastoji se od brojeva od 1 do 9, gdje 1 označava podjednaku važnost a 9 ekstremnu važnost (prioritet) jednog kriterija nasuprot drugom. [10]

Međusobne se usporedbe objedinjuju u matrici odlučivanja (1) po sljedećem principu:

ako je ocjena na lijevoj strani, u redak se unosi stvarna vrijednost, a ako je ocjena na desnoj strani, unosi se recipročna vrijednost.

	SIGURNOST	UČESTALOST KVARA	DIZAJN	
SIGURNOST	1	3	5	
UČESTALOST KVARA	0,33	1	2	
DIZAJN	0,2	0,5	1	

(1)

Iz (1) vidljivo je kako je kriterij sigurnosti tri puta važniji od kriterija učestalosti kvara, odnosno da je kriterij dizajna pet puta manje važniji od kriterija sigurnosti. Po dijagonalni matrice nalaze se jedinice jer se kriteriji ne uspoređuju sami sa sobom, odnosno, podrazumijeva se da su one međusobno jednake važnosti pa im je zato dodijeljena jedinica. Matrica kriterija (odlučivanja) se množi sama sa sobom (2).

$$\begin{array}{ccccccc}
 1 & 3 & 5 & & 1 & 3 & 5 \\
 0,33 & 1 & 2 & * & 0,33 & 1 & 2 \\
 0,2 & 0,5 & 1 & & 0,2 & 0,5 & 1
 \end{array} = \begin{array}{ccc}
 2,99 & 8,5 & 16 \\
 1,06 & 2,99 & 5,65 \\
 0,565 & 1,6 & 3
 \end{array} \quad (2)$$

Vrijednosti u recima dobivene matrice se sumiraju i normaliziraju te se tako dobiva prvi vektor prioriteta. (3),(4)

$$\begin{array}{rcl}
 2,99 & + & 8,5 & + & 16 & = & 27,49 \\
 1,06 & + & 2,99 & + & 5,65 & = & 9,7 \\
 0,565 & + & 1,6 & + & 3 & = & 5,165
 \end{array} \quad (3)$$

Ukupno: 42,355

$$\begin{array}{rcl}
 27,49/42,355 & = & 0,64904 \\
 9,7/42,355 & = & 0,22902 \quad \text{--> prvi vektor prioriteta} \\
 5,165/42,355 & = & 0,12195
 \end{array} \quad (4)$$

Prva iteracija množi se sama sa sobom te se opet sumiraju vrijednosti njenih redaka, dobiveni se vektor stupac normalizira te to predstavlja drugi vektor prioriteta. Matrice odlučivanja prvo se množe (5).

$$\begin{array}{ccccccc}
 2,99 & 8,5 & 16 & & 2,99 & 8,5 & 16 \\
 1,06 & 2,99 & 5,65 & * & 1,06 & 2,99 & 5,65 \\
 0,565 & 1,6 & 3 & & 0,565 & 1,6 & 3
 \end{array} = \begin{array}{ccc}
 26,99 & 76,43 & 143,86 \\
 9,531 & 26,99 & 50,803 \\
 5,0803 & 14,386 & 27,08
 \end{array} \quad (5)$$

Zatim se sumiraju redovi matrice (6).

$$\begin{array}{rcl}
 26,99 & + & 76,43 & + & 143,86 & = & 247,28 \\
 9,531 & + & 26,99 & + & 50,803 & = & 87,324 \\
 5,0803 & + & 14,386 & + & 27,08 & = & 46,5463
 \end{array} \quad (6)$$

Ukupno: 381,5463

Slijedi normalizacija sume redova na način prikazan u (7), čime se određuje drugi vektor prioriteta.

$$\begin{array}{rcl} 247,28/381,5463 & 0,64877 & \\ 87,324/381,5463 & 0,22902 & \rightarrow \text{drugi vektor prioriteta} \\ 46,5463/381,5463 & 0,12212 & \end{array} \quad (7)$$

Drugi je vektor potrebno oduzeti od prvog. Ako su vrijednosti dovoljno male (obično se uzima točnost na tri decimale), drugi se prihvća kao konačni vektor prioriteta kriterija. Ako nije tako, potrebno je nastaviti s iteracijama dok se ne dobije dovoljno mala razlika (8)

$$\begin{array}{rcl} 0,64904 & 0,64877 & 0,00027 \\ 0,22902 & - & 0,22902 & = & 0 \\ 0,12195 & 0,12212 & -0,00017 \end{array} \quad (8)$$

Iz prve matrice odlučivanja određuje se najznačajniji kriterij. Najznačajniji kriterij je onaj čija je vrijednost u konačnom vektoru prioriteta najveća (9).

	SIGURNOST	UČESTALOST KVARA	DIZAJN	
SIGURNOST	1	3	5	0,64877
UČESTALOST KVARA	0,33	1	2	0,22902
DIZAJN	0,2	0,5	1	0,12212

(9)

Matrica odlučivanja Vektor prioriteta

Iz (9) vidljivo je da je najznačajniji kriterij Sigurnost jer je njegova vrijednost u konačnom vektoru prioriteta najveća.

8.2. 2. Faza - Određivanje najznačajnije alternative

Postupak određivanja najznačajnijeg kriterija isti je i za određivanje najznačajnije alternative. Na Tablici 1.1. prikazane su matrice odlučivanja alternativa za svaki pojedini kriterij.

SIGURNOST				UČESTALOST KVARA				DIZAJN			
	Nokia	Samsung	Apple		Nokia	Samsung	Apple		Nokia	Samsung	Apple
Nokia	1	0,2	0,33	Nokia	1	0,5	3	Nokia	1	0,33	0,17
Samsung	5	1	2	Samsung	2	1	5	Samsung	3	1	0,5
Apple	3	0,5	1	Apple	0,33	0,2	1	Apple	6	2	1

Tablica 1.1. Definiranje matrice odlučivanja za alternative

Nakon što se provedu iteracije za alternative moguće je odrediti koja je alternativa najbolja u kojem kriteriju.

Zatim se provodi usporedba matrice odlučivanja alternativa s konačnim vektorima prioriteta alternativa za svaki pojedini kriterij. Najveća vrijednost u konačnom vektoru prioriteta alternativa označava najbolju alternativu za određeni kriterij.

Kvantitativne se kriteriji uspoređuju na način da se u vektor stupac unesu kvantitativne vrijednosti svake alternative, te se ta matrica normalizira. Opet se odabire najveća vrijednost rezultata normalizacije (10).

Trajanje baterije (h)			(10)
Nokia	12	12/32=0,375	
Samusung	11	11/32=0,344	
Apple	9	9/32=0,281	
Ukupno:	32		

Iz (10) vidljivo je kako Nokia ima najtrajniju bateriju.

No, ako je cilj odabir modela s najmanjim trajanjem baterije, tada, kako bi se zadovoljila matematička forma AHP metode koja sugerira odabir najveće vrijednosti, potrebno je maksimizirati vektor prioriteta. Maksimizacija vektora prioriteta provodi se oduzimanjem normalizirane vrijednosti kriterija od broja jedan te zbrajanjem dobivenih vrijednosti.

Dobivene se vrijednosti dijele s zbrojem, odnosno, ponovno se normaliziraju, kako je prikazano na (11).

Trajanje baterije (h)				(11)
Nokia	12	$1-(12/32)=0,625$	$0,625/2=0,3125$	
Samusung	11	$1-(11/32)=0,656$	$0,656/2=0,328$	
Apple	9	$1-(9/32)=0,719$	$0,719/2=0,3595$	
Ukupno:	32	2		

Iz (11) vidljivo je kako Apple ima najmanju trajnost baterije, no vektor prioriteta je maksimiziran pa je željena najpovoljnija trajnost prikazana najvećom vrijednošću.

8.3. 3. Faza - Određivanje konačnog rješenja (cilja)

Kako pri donošenju ovih odluka postoji vrlo velik broj kriterija teško je svaki put provoditi ovaj postupak ručno. Zato postoje napredni računalni programi koji omogućavaju provedbu AHP metode i donošenje odluke te različiti, grafički i analitički prikaz podataka.

Također, programom se lako provodi i analiza osjetljivosti kojom se ispituju kako promjene ulaznih podataka djeluju na izlazne rezultate te laka mogućnost usporedbe i provedba različitih varijanti donošenja odluka. [5]

Konačni cilj određuje se množenjem vektora prioriteta alternativa i vektora prioriteta kriterija čime se dobiva vektor prioriteta cilja (12). Najveća vrijednost u vektoru prioriteta cilja predstavlja konačno rješenje.

	Sigurnost	Učestalost kvara	Dizajn				
Nokia	0,108	0,309	0,1	0,6488	Sigurnost	0,154	(12)
Samsung	0,582	0,582	0,3	* 0,229	Učestalost kvara	= 0,548	
Apple	0,309	0,109	0,6	0,1221	Dizajn	0,298	

Iz (12) vidljivo je kako je kao konačan cilj odabran Samsung koji je po svim kriterijima bio bolji od ostalih alternativa.

8.4. Problem troškova u AHP metodi

Kod kompleksnih zadataka preporučljivo je zasebno razmatrati troškove kako bi se izbjegla mogućnost dobivanja preskupe alternative s velikim brojem benefita, a cilj je dobiti jeftinu alternativu sa što je moguće većim brojem benefita. Rješenje leži u izračunu omjera benefita (B) i troškova (T), na samom kraju, prije odabira konačnog cilja. Benefiti su vrijednosti vektori prioriteta cilja za pojedinu alternativu.

	Trošak (eur)	Normalizirani trošak	Benefit/Trošak	
NOKIA	500	$500/3000=0,17$	$0,154/0,17=0,9059$	(13)
SAMSUNG	1000	$1000/3000=0,33$	$0,548/0,33=1,661$	
APPLE	1500	$1500/3000=0,5$	$0,298/0,50=0,596$	
Ukupno:	3000			

Iz (13) vidljivo je kako najbolji (najveći) omjer benefita i troška ima Samsung, te se on predlaže za kupnju kao optimalna alternativa.

8.5. Konzistentnost

Konzistentnost cjelokupnog procesa provjerava se preko indeksa konzistentnosti koji mora biti manji od 10% da bi se odluka prihvatila kao valjana i konzistentna. *Konzistentnost označava dosljednost donositelja odluke u svojim odlukama i procjenama.*

U matrici odlučivanja sumiraju se stupci te se suma svakog stupca množi s konačnim redom prioriteta (14) kako bi se izračunala konstanta λ_{\max} (15).

	SIGURNOST	UČESTALOST KVARA	DIZAJN	
SIGURNOST	1	3	5	0,6488
UČESTALOST KVARA	0,33	1	2	0,229
DIZAJN	0,2	0,5	1	0,1221
Ukupno:	1,53	4,5	8	

Matrica
odlučivanja

Vektor prioriteta

(14)

$$\lambda_{\max} = 1,53 \cdot 0,6488 + 4,5 \cdot 0,2290 + 8 \cdot 0,1221 = 3 \quad (15)$$

Nakon što je izračunata λ_{\max} , računa se indeks konzistentnosti (16) $CI = (\lambda_{\max} - n) / (n - 1)$, gdje je n broj kriterija. Indeks konzistentnosti služi za izračun omjera konzistencije $CR = CI / RI$ (17), gdje je RI slučajni indeks (indeks konzistencije) koji se primjenjuje samo ako je broj kriterija veći ili jednak tri.

RI je tablična vrijednost i njegove vrijednosti prikazane su u Tablici 1.2.

n	1	2	3	5	6	7	8	9	10
RI	0	0	0,52	1,11	1,25	1,35	1,4	1,45	1,49

Tablica 1.2. Indeks konzistencije

U Tablici 1.2. prikazane su vrijednosti omjera konzistentnosti za do deset značajki.

Ako je CR manji od 0,1 tada se rješenje prihvća kao konzistentno. U slučaju većeg broja, potrebno je preispitati odluke i procjene korisnika. Granica povoljnog indeksa konzistentnosti uzima se prema preporuci tvorca ove metode, Thomasa Saatyja. [10]

U obrađivanom primjeru dobiveni su sljedeći rezultati:

$$CI = (3 - 3) / (3 - 1) = 0 \quad (16)$$

$$CR = CI / 0,52 = 0 < 0,1 \rightarrow \text{rezultati su konzistentni.} \quad (17)$$